

CRISTINA DE QUEIROZ TELLES MAFFRA

**MODELAGEM DA UMIDADE DO SOLO A PARTIR DE DADOS
MULTIESPECTRAIS DOS SISTEMAS LANDSAT, ASTER E MODIS**

Tese apresentada como requisito parcial
à obtenção do grau de Doutor, pelo
Curso de Pós-Graduação em Ciências
Geodésicas, Setor de Ciências da Terra,
Universidade Federal do Paraná.

Orientador: Prof. Dr. Jorge Antonio
Silva Centeno

CURITIBA
2004

**“MODELAGEM DA UNIDADE DO SOLO A PARTIR DE
DADOS MULTIESPECTRAIS DOS SISTEMAS LANDSAT,
ASTER E MODIS”**

POR

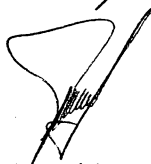
CRISTINA DE QUEIROZ TELLES MAFFRA

Tese nº 034 aprovada como requisito parcial do grau de Doutor no
Curso de Pós-Graduação em Ciências Geodésicas da Universidade
Federal do Paraná, pela Comissão formada pelos professores:

Curitiba, 28 de julho de 2004.



Prof. Dr. Jorge Antonio Silva Centeno - Orientador e Presidente (UFPR)



Prof. Dr. Maurício Almeida Noernberg – Membro (UFPR)



Prof. Dr. Alzir Felipe Buffara Antunes - Membro (UFPR)



Prof. Dr. Quintino Dalmolin - Membro (UFPR)



Prof. Dr. Leonardo José Cordeiro dos Santos – Membro (UFPR)



Eng. Dr. Flavio Deppe - Membro (SIMEPAR)

TERMO DE APROVAÇÃO

CRISTINA DE QUEIROZ TELLES MAFFRA

**MODELAGEM DA UMIDADE DO SOLO A PARTIR DE DADOS MULTIESPECTRAIS DOS
SISTEMAS LANDSAT, ASTER E MODIS**

Tese aprovada como requisito parcial para obtenção do grau de Doutor no Curso de pós-graduação em Ciências Geodésicas, Setor de Ciências da Terra, Universidade Federal do Paraná, pela seguinte banca examinadora:

Orientador: Prof. Dr. Jorge Antonio Silva Centeno
Departamento de Geomática, UFPR

Prof. Dr. Mauricio Almeida Noernberg
Departamento de Ciências do Mar, UFPR

Prof. Dr. Alzir Felipe Bufara Antunes
Departamento de Geomática, UFPR

Prof. Dr. Quintino Dalmolin
Departamento de Geomática, UFPR

Prof. Dr. Leonardo José Cordeiro dos Santos
Departamento de Geografia, UFPR

Eng. Dr. Flavio Deppe
SIMEPAR

Curitiba, 28 de julho de 2004

AGRADECIMENTOS

A realização desta tese não seria possível sem a colaboração de muitas pessoas, as quais gostaria de agradecer.

Inicialmente gostaria de agradecer ao meu orientador, Prof. Dr. Jorge A. S. Centeno, por sua dedicação, apoio e paciência durante todas as fases de elaboração deste trabalho.

Meus agradecimentos também aos professores Armin Gruen do ETH – Zurich, e ao Prof. Mario Ferri, da Universidade de Nápoles, agradecimento especial ao colega Marc Honikel, com o qual trabalhei no período de estada no ETH.

Agradecimentos especiais ao Departamento de Geomática, Setor de Ciências da Terra, da Universidade Federal do Paraná, a seus funcionários e professores pela sempre dedicação e apoio e a CAPES pelo provimento de bolsa de estudo no período de permanência no Brasil.

Aos colegas cultivados durante minha estada em Curitiba, Zurique, Nápoles e Brasília, agradeço imensamente o carinho, o incentivo e a compreensão pelas ausências, durante o período de realização deste trabalho.

Agradecimentos especiais à minha família, principalmente aos meus pais Lúcia e Walter e ao meu marido Marco, pelo amor, apoio e auxílio em tantos momentos.

A todos, meus agradecimentos mais sinceros.

SUMÁRIO

LISTA DAS FIGURAS.....	VIII
LISTA DOS GRÁFICOS.....	IX
LISTA DAS TABELAS	XI
RESUMO	XIII
ABSTRACT	XIV
1 INTRODUÇÃO	1
1.1 JUSTIFICATIVA	3
1.2 OBJETIVO GERAL	4
1.3 OBJETIVOS ESPECÍFICOS	4
1.4 ÁREA DE ESTUDO	5
2 REVISÃO DA LITERATURA	7
2.1 SENSORIAMENTO REMOTO E UMIDADE DO SOLO	7
2.2 ESTUDO DA UMIDADE DO SOLO NAS FAIXAS DO VISÍVEL ATÉ O INFRAVERMELHO MÉDIO	10
2.3 ESTUDO DA UMIDADE DO SOLO NA REGIÃO TERMAL DO ESPECTRO ELETROMAGNÉTICO	10
2.4 ÍNDICES UTILIZADOS NA DETECÇÃO DA UMIDADE DO SOLO..	12
2.5 SISTEMAS E SENSORES.....	15
2.6 RADAR E OUTRAS FORMAS DE DETECÇÃO DA UMIDADE	16
2.7 MODELAGEM DE PARÂMETROS FÍSICOS DOS SOLOS ATRAVÉS DE SENSORIAMENTO REMOTO	17
3 MATERIAIS	19
3.1 RECOBRIMENTO DAS IMAGENS.....	20
3.2 IMAGENS ASTER– ADVANCED SPACEBORNE THERMAL EMISSION AND REFLECTANCE RADIOMETER	21
3.2.1 Reflectância da Superfície	22
3.2.2 Temperatura de Superfície (TS).....	23
3.3 MODIS - MODERATE RESOLUTION IMAGING SPECTRORADIOMETER.....	24
3.3.1 Reflectância da Superfície	25
3.3.2 Temperatura Superficial Noturna (TSN)	25
3.4 LANDSAT ETM+	26
4 MÉTODOS.....	27
4.1 DESCRIÇÃO GERAL DOS MÉTODOS APLICADOS.....	27
4.2 PRIMEIRA FASE: PROCESSAMENTO DAS IMAGENS.....	27

4.2.1	Georreferenciamento das Imagens.....	28
4.2.2	Pré-Processamento das Imagens Landsat	29
4.2.3	Conversão dos NDs para valores de reflectância.....	29
4.2.4	Índices e Bandas Utilizados para cada Sensor	31
4.2.5	Transformação das Componentes Principais	34
4.2.6	Transformação <i>Tasseled Cap</i>	35
4.3	SEGUNDA FASE: OBTENÇÃO DOS DADOS DE VERDADE DE CAMPO	39
4.3.1	Seleção do Acumulado de Chuvas.....	39
4.3.2	Critérios para escolha dos Pontos e Forma de Medição dos Dados ...	41
4.3.3	Critérios para escolha dos Grupos de Solos.....	42
4.4	TERCEIRA FASE: CORRELAÇÃO ENTRE ACUMULADO DE CHUVAS X DADOS ESPECTRAIS: CRITÉRIOS PARA ESCOLHA DAS ANÁLISES	47
4.4.1	Análise Regressão Múltipla	48
4.4.2	GMDH - Group Method of Data Handling.....	50
4.4.3	Análise Discriminante.....	53
4.5	QUARTA FASE: VERIFICAÇÃO DOS RESULTADOS	55
4.5.1	Teste Kolmogorov-Smirnov.	55
5	MODELOS DE REGRESSÃO MÚLTIPLA.....	58
5.1	LANDSAT	59
5.1.1	Solo B.....	59
5.1.2	Solos H & I	60
5.1.3	Solos B, F & G	60
5.1.4	Solos D, E, H & I	61
5.1.5	Todos os Tipos de Solos	61
5.1.6	Avaliação dos modelos para os dados Landsat.....	62
5.2	ASTER.....	64
5.2.1	Solo B.....	64
5.2.2	Solo H & I	65
5.2.3	Solos B, F & G	65
5.2.4	Solos D, E, H & I	66
5.2.5	Todos os Tipos de Solos	66
5.2.6	Avaliação dos modelos para os dados ASTER.....	67
5.3	MODIS.....	68
5.3.1	Solo B.....	69
5.3.2	Solos H & I	69
5.3.3	Solos B, F & G	70
5.3.4	Solos D, E, H & I	70
5.3.5	Todos os Tipos de Solos	71
5.3.6	Resultados Obtidos para as Imagens MODIS.....	71
6	APLICAÇÃO DO ALGORITMO GMDH	74
6.1	LANDSAT ETM	74

6.1.1	Solo B.....	74
6.1.2	Solos H & I	76
6.1.3	Solos B, F & G	77
6.1.4	Solos D, E, H & I	79
6.1.5	Todos os tipos de Solos.....	81
6.1.6	Resultados Gerais obtidos para o Landsat ETM+ através do GMDH	83
6.2	ASTER.....	84
6.2.1	Solo B.....	84
6.2.2	Solos H & I	85
6.2.3	Solos B, F & G	87
6.2.4	Solos D, E, H & I	89
6.2.5	Todos os Tipos de Solos	89
6.2.6	Resultados Gerais obtidos para o ASTER através do GMDH.....	91
6.3	MODIS.....	92
6.3.1	Solo B.....	92
6.3.2	Solos H & I	94
6.3.3	Solos B, F & G	95
6.3.4	Solos D, E, H & I	96
6.3.5	Modelagem com Todos os Tipos de Solos	97
6.3.6	Resultados Gerais obtidos para o MODIS através do GMDH	99
7	MODELOS BASEADOS EM REGRESSÃO MÚLTIPLA	
	APRIMORADOS.....	101
7.1	LANDSAT ETM+	101
7.1.1	Solo B.....	101
7.1.2	Solos H & I	102
7.1.3	Solos B, F & G	102
7.1.4	Solos D, E, H & I	103
7.1.5	Todos os Tipos de Solos	103
7.1.6	Resultados obtidos para o Landsat.....	103
7.2	ASTER.....	105
7.2.1	Solo B.....	105
7.2.2	Solos H & I	106
7.2.3	Solos B, F e G	106
7.2.4	Solos D, E, H & I	106
7.2.5	Todos os Solos	107
7.2.6	Resultados obtidos para o ASTER.....	107
7.3	MODIS.....	109
7.3.1	Solo B.....	109
7.3.2	Solos H & I	110
7.3.3	Solos B, F e G	110
7.3.4	Solos D, E, H e I	110
7.3.5	Todos os Solos	111
7.3.6	Resultados obtidos para as Imagens MODIS.....	111
8	MODELAGEM USANDO A ANÁLISE DISCRIMINANTE.....	113
8.1	LANDSAT	114

8.2	ASTER.....	115
8.3	MODIS.....	117
9	ANÁLISE E DISCUSSÃO DOS RESULTADOS OBTIDOS	119
9.1	ANÁLISE DOS RESULTADOS _ LANDSAT ETM+.....	119
9.2	ANÁLISES DOS RESULTADOS _ ASTER	123
9.3	ANÁLISE DOS RESULTADOS _ MODIS	127
9.4	RESULTADOS DAS ANÁLISES DISCRIMINANTES	131
9.5	DISCUSSÃO - RESULTADOS ESPECTRAIS	132
9.6	ANÁLISE DOS RESULTADOS VOLTADA AO ESTUDO DE MOVIMENTOS DE MASSA	136
10	CONCLUSÕES E RECOMENDAÇÕES	139
10.1	CONCLUSÕES	139
10.2	RECOMENDAÇÕES	142
	REFERÊNCIAS BIBLIOGRÁFICAS.....	144
	ANEXO I - DADOS DE ACÚMULO DE CHUVA.....	149

LISTA DAS FIGURAS

FIGURA 1.1 – LOCALIZAÇÃO DA ÁREA DE ESTUDO – REGIÃO DE CAMPANIA, ITÁLIA.	5
FIGURA 2.1 – COMPORTAMENTO ESPECTRAL DO SOLO COM DIFERENTES TAXAS DE UMIDADE	8
FIGURA 3.1 - BANDAS ESPECTRAIS DO SENSOR ASTER, NO ESPECTRO ELETROMAGNETICO.	21
FIGURA 3.2 - DIFERENÇA ANGULAR NA AQUISIÇÃO DAS 2 BANDA DO INFRAVERMELHO PRÓXIMO	22
FIGURA 4.1 – EM A : NDVI E EM B : NDII, EM 3D PARA A ESTAÇÃO PLUVIOMÉTRICA DE ACERRA, COM EXAGERO VERTICAL DE 2.0 EM AMBAS FIGURAS:	33
FIGURA 4.2 – COMPONENTES PRINCIPAIS ENTRE ETM5 E ETM7, ESTAÇÃO DE ACERRA. EM3D.....	35
FIGURA 4.3 – TRANSFORMAÇÃO TASSELED CAP, BANDA UMIDADE, ESTAÇÃO DE ACERRA EM 3D.....	38
FIGURA 4.4 – DISTRIBUIÇÃO DAS ESTAÇÕES PLUVIOMÉTRICAS NA ÁREA DE ESTUDO	39
FIGURA 4.5 – POSIÇÃO NA VERTENTE DO PONTO DE MEDIÇÃO DOS DADOS ESPECTRAIS	41
FIGURA 4.6 - ESQUEMA GERAL DA ESTRUTURA DO ALGORITMO GMDH.....	51
FIGURA 4.7 – FRAÇÃO CUMULATIVA , TESTE K-S.....	57
FIGURA 9.1 – IMAGEM UMIDADE, GERADA A PARTIR DE IMAGENS MODIS, ESTAÇÃO DE ACERRA. EM3D.	137
FIGURA 9.2 – IMAGEM UMIDADE, GERADA A PARTIR DE IMAGENS ASTER, ESTAÇÃO DE ACERRA. EM3D.	138

LISTA DOS GRÁFICOS

GRÁFICO 6.1 – RELAÇÃO ENTRE VALORES OBTIDOS E VALORES OBSERVADOS, LANDSAT, SOLO B	75
GRÁFICO 6.2 – RELAÇÃO ENTRE VALORES OBTIDOS E VALORES OBSERVADOS, LANDSAT, SOLO B	76
GRÁFICO 6.3 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS, LANDSAT SOLOS H&I	76
GRÁFICO 6.4 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS, LANDSAT, SOLOS H&I	77
GRÁFICO 6.5 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS. EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, SOLOS B,F & G	78
GRÁFICO 6.6 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS. EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, SOLOS B,F & G	79
GRÁFICO 6.7 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT , SOLOS D,E,H&I.	80
GRÁFICO 6.8 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, SOLOS D,E,H&I	81
GRÁFICO 6.9 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS. EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, TODOS OS TIPOS DE SOLOS	82
GRÁFICO 6.10 –VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS. EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, TODOS OS TIPOS DE SOLOS	82
GRÁFICO 6.11 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS	85
GRÁFICO 6.12 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS	86
GRÁFICO 6.13 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS	87
GRÁFICO 6.14 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS	88
GRÁFICO 6.15 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS	88
GRÁFICO 6.16 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO	89
GRÁFICO 6.17 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO	90
GRÁFICO 6.18 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO	91
GRÁFICO 6.19 – RESULTADOS OBTIDOS COM O ALGORITMO GMDH UTILIZANDO-SE TODAS AS VARIÁVEIS INDEPENDENTES	93
GRÁFICO 6.20 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS	94
GRÁFICO 6.21 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS	95
GRÁFICO 6.22 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO	95

GRÁFICO 6.23 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO.....	96
GRÁFICO 6.24 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO.....	97
GRÁFICO 6.25 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO.....	98
GRÁFICO 6.26 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO.....	98

LISTA DAS TABELAS

TABELA 3.1 - BANDAS DO SENSOR ASTER, SATÉLITE TERRA - NASA	21
TABELA 3.2 – BANDAS DO SENSOR MODIS, SATELITE TERRA - NASA	24
TABELA 3.3 – CARACTERÍSTICAS DAS MISSÕES LANDSAT	26
TABELA 3.4 - BANDAS DO LANDSAT 7 ETM+	26
TABELA 4.1 – RADIANCIA PARA BANDAS ESPECTRAIS ETM ($W/M^2 * \mu M$).....	30
TABELA 4.2 - VALORES DE GAIN PARA ÁREA EM ESTUDO, NOVEMBRO DE 2002	30
TABELA 4.3 - IRRADIÂNCIA ESPECTRAL SOLAR PARA LANDSAT 7 ($W/M^2 * \mu M$)	31
TABELA 4.4 - COEFICIENTES <i>TASSELED CAP</i> PARA LANDSAT 7 ETM+	37
TABELA 4.5 – NÚMERO DE AMOSTRAS UTILIZADAS POR SENSOR PARA OS SOLOS B E H& I	46
TABELA 4.6 – NÚMERO DE AMOSTRAS UTILIZADAS POR SENSOR PARA OS GRUPOS DE SOLOS B, F& G D, E,H&I.....	47
TABELA 4.7 – NÚMERO DE AMOSTRAS UTILIZADAS POR SENSOR PARA TODOS OS SOLOS	47
TABELA 4.8 – CÁLCULO DE $D_{CRÍTICO}$ DE ACORDO COM O NÍVEL DE SIGNIFICÂNCIA ESTATÍSTICA.....	56
TABELA 5.1 –REGRESSÕES MÚLTIPLAS Nº 1, REALIZADAS COM A IMAGEM LANDSAT	63
TABELA 5.2 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, LANDSAT, 1º REGRESSÃO	64
TABELA 5.3 –REGRESSÕES MÚLTIPLAS Nº 1, REALIZADAS COM AS IMAGENS ASTER.....	67
TABELA 5.4 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, ASTER, 1º REGRESSÃO	68
TABELA 5.5 –REGRESSÕES MÚLTIPLAS Nº 1, REALIZADAS COM AS IMAGENS MODIS.....	72
TABELA 5.6 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, MODIS, 1º REGRESSÃO	73
TABELA 6.1 –MODELAGENS COM ALGORITMO GMDH, REALIZADAS COM A IMAGEM LANDSAT	83
TABELA 6.2 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, LANDSAT, ALGORITMO GMDH	84
TABELA 6.3 – DADOS REFERENTES AS MODELAGENS COM ALGORITMO GMDH, REALIZADAS COM AS IMAGENS ASTER.....	91
TABELA 6.4 – TESTES ESTATÍSTICOS:KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO.....	92
TABELA 6.5 – DADOS REFERENTES AS MODELAGENS COM ALGORITMO GMDH, REALIZADAS COM AS IMAGENS MODIS	99
TABELA 6.6 – TESTES ESTATÍSTICOS:KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO	100
TABELA 7.1 –REGRESSÕES MÚLTIPLAS Nº 2, REALIZADAS COM A IMAGEM LANDSAT	104
TABELA 7.2 – TESTES ESTATÍSTICOS:KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO.....	105
TABELA 7.3 –REGRESSÕES MÚLTIPLAS Nº 2, REALIZADAS COM AS IMAGENS ASTER.....	108
TABELA 7.4 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, IMAGENS ASTER, 2ºREGRESSÃO MÚLTIPLA.....	109
TABELA 7.5 – DADOS REFERENTES AS REGRESSÕES MÚLTIPLAS Nº 2, REALIZADAS COM AS IMAGENS MODIS	112
TABELA 7.6 – TESTES ESTATÍSTICOS:KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO.....	112
TABELA 8.1 – CATEGORIAS DE ACUMULADO DE CHUVA PARA A IMAGEM LANDSAT E ASTER	113
TABELA 8.2 – CATEGORIAS DE ACUMULADO DE CHUVA PARA A IMAGEM MODIS	113
TABELA 8.3 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4, LANDSAT	114
TABELA 8.4 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4, LANDSAT	115
TABELA 8.5 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4 - ASTER	116
TABELA 8.6 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4, ASTER	117
TABELA 8.7 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4, MODIS.....	118
TABELA 9.1 – RESULTADOS OBTIDOS ATRAVÉS DAS REGRESSÕES MÚLTIPLAS PARA A MODELAGEM DO AC4 PARA A IMAGEM LANDSAT.....	120
TABELA 9.2 – RESULTADOS OBTIDOS COM O TESTE K-S PARA A IMAGEM LANDSAT	121
TABELA 9.3 – RESULTADOS OBTIDOS COM A CORRELAÇÃO ENTRE OS DADOS OBSERVADOS E AQUELES GERADOS PELO MODELO (M) E ENTRE OS DADOS OBSERVADOS E AS AMOSTRAS UTILIZADAS PARA A VERIFICAÇÃO DO MODELO (V).....	121

TABELA 9.4 – RESULTADOS OBTIDOS ATRAVÉS DAS REGRESSÕES MÚLTIPLAS PARA A MODELAGEM DO AC4 PARA AS IMAGENS ASTER.....	123
TABELA 9.5 – RESULTADOS OBTIDOS COM O TESTE K-S APLICADO PARA AS IMAGENS ASTER	124
TABELA 9.6 – RESULTADOS OBTIDOS COM A CORRELAÇÃO ENTRE OS DADOS OBSERVADOS E AQUELES GERADOS PELO MODELO (M) E ENTRE OS DADOS OBSERVADOS E AS AMOSTRAS UTILIZADAS PARA A VERIFICAÇÃO DO MODELO (V).....	125
TABELA 9.7 – RESULTADOS OBTIDOS ATRAVÉS DAS REGRESSÕES MÚLTIPLAS PARA A MODELAGEM DO AC4 PARA AS IMAGENS MODIS	127
TABELA 9.8 – RESULTADOS OBTIDOS COM O TESTE K-S PARA AS IMAGENS ASTER	128
TABELA 9.9 – RESULTADOS OBTIDOS COM A CORRELAÇÃO ENTRE OS DADOS OBSERVADOS E AQUELES GERADOS PELO MODELO (M) E ENTRE OS DADOS OBSERVADOS E AS AMOSTRAS UTILIZADAS PARA A VERIFICAÇÃO DO MODELO (V).....	129
TABELA A1 – ACUMULADOS DE CHUVA.....	149
TABELA A2 - LOCALIZAÇÃO DAS ESTAÇÕES.....	151

RESUMO

Neste trabalho, a umidade do solo é estudada através da análise multitemporal de imagens multiespectrais em escala de semidetalhe e regional. Dados espectrais dos sensores Landsat ETM, ASTER e MODIS foram obtidos em diferentes tipos de solos da região de Campania, sul da Itália, e esta informação foi correlacionada a dados pontuais de pluviosidade através da análise multivariada. O objetivo é gerar um modelo ótimo para cada sensor, capaz de contribuir na predição da umidade do solo. Na tentativa de aprimorar os dados espectrais foram gerados índices, tais como NDVI, NDII, Transformação Tasseled Cap e Análise dos Componentes Principais das bandas do infravermelho. Também foram utilizadas imagens da Temperatura Superficial (ASTER) e Temperatura Superficial Noturna (MODIS). Na obtenção do modelo foram utilizadas a Análise Discriminante, a Análise de Correlação Múltipla e a GMDH-rede neural polinomial (PNN) buscando-se uma equação ótima que contivesse as bandas/índices espectrais mais sensíveis à umidade do solo para cada sensor. Para a verificação dos resultados obtidos utilizou-se os testes de Kolmogorov-Smirnov e correlação. Os resultados revelaram êxito nas modelagens com as imagens ASTER e indicaram como comprimento de onda mais eficiente para a caracterização da umidade do solo o infravermelho entre 2.185 – 2.225 μm , 2.295 – 2.365 μm e 2.360 – 2.430 μm . Para o Landsat somente a modelagem realizada para um tipo individual de solo pôde ser considerada satisfatória e o modelo obtido apresentou os índices NDII, Tasseled Cap – umidade e banda termal como variáveis. No caso das imagens MODIS, os resultados podem ser considerados aceitáveis, não obstante a dificuldade em se modelar valores mais elevados do acumulado de chuva e mostram o predomínio dos comprimentos 0.54 – 0.56 μm e 2.10 – 2.15 μm . Tanto para o ASTER como para o MODIS as modelagens mais eficientes indicaram a utilização da Temperatura Superficial. Com este estudo conclui-se serem os sensores ASTER e MODIS os mais eficientes na determinação da umidade do solo por meio da utilização de bandas no infravermelho médio combinadas a Temperatura Superficial.

Palavras-chave: umidade do solo, Sensoriamento Remoto, análise multivariada, Landsat, ASTER, MODIS.

ABSTRACT

This work concerns the study of soil moisture through multi-temporal analysis of multi-spectral images at regional and local scale. Spectral data from sensors Landsat ETM, ASTER and MODIS were obtained for different soil types, from Campania region, south Italy, and this information was correlated to measured rain fall data through multivariate analysis. The objective is generate for each sensor an optimal model able to predict soil moisture. In the attempt of improving the spectral response, indices such as NDVI, NDII, Tasseled Cap Transformation and Principal Component Analysis of the infrared bands were generated. Images of Superficial Temperature (ASTER) and Nocturnal Superficial Temperature (MODIS) were also used. The Discriminant Analysis, the Multiple Regression Analysis and a neural-network GMDH polynomial (PNN) were used for the generation of the model, looking for an optimal equation for each sensor which would include the indices/spectral bands more sensitive to soil moisture. The validation of the results was carried out using the Kolmogorov-Smirnov test and correlation analysis. The models generated showed the tendency to emphasize the infrared wavelength for all three sensors. For Landsat, just the model for one individual soil type could be considered as satisfactory, and the model obtained presented as variables the index NDII, Tasseled Cap – moisture and infrared band. The results obtained with ASTER images were satisfactory and revealed that the most efficient bands for characterising the soil moisture were between 2.185 – 2.225 μm , 2.295 – 2.365 μm and 2.360 – 2.430 μm . For MODIS, the results can be considered acceptable, notwithstanding the difficulties at modelling higher values of cumulated rain fall, and show the dominance of the wavelengths 0.54 – 0.56 μm and 2.10 – 2.15 μm . For both ASTER and MODIS, the most efficient models indicate the use of Surface Temperature images. This work leads to the conclusion that ASTER and MODIS are both efficient for soil moisture detection that can be done using middle infrared bands combined with Surface Temperature images.

Key-words: soil moisture, remote sensing, multivariate analysis, Landsat, ASTER, MODIS.

1 INTRODUÇÃO

O estudo da umidade do solo tem a sua relevância devido às suas diversas aplicações como no estudo da agricultura, para o gerenciamento da irrigação; no estudo de processos hidrológicos, para previsão de enchentes; e no estudo de certos desastres geológicos como movimentos de massa, onde a umidade do solo pode ser associada a um dos fatores desencadeadores de tal evento.

São várias as definições dadas ao termo umidade do solo. As diferenças existem por tratar-se de um parâmetro utilizado em diversas disciplinas. Um conceito geral que pode ser utilizado é o da descrição da umidade que existe nos primeiros metros do solo e que interage com a atmosfera através da evapotranspiração e da precipitação (KITE e PIETRONIRO, 1996).

As técnicas tradicionais de medidas da umidade do solo (gravimétricas, tensiométricas, higrométricas) não levam em consideração a variabilidade espacial e temporal típica deste parâmetro. Além disso, são técnicas custosas e difíceis de serem aplicadas em um estudo regional.

Diante de tais perspectivas o Sensoriamento Remoto apareceu como uma alternativa, capaz de contribuir para superar esta deficiência. Porém, pelo fato de se obter medidas indiretas da umidade do solo, erros causados pela variação do tipo de solo, variação da rugosidade da superfície, cobertura vegetal, e inadequada cobertura espacial e temporal existem e podem comprometer a acurácia dos resultados.

Quando o estudo da umidade do solo é feito em regiões montanhosas, este tópico torna-se ainda mais delicado por incluir uma variável a mais: a topografia. Sabe-se que em terrenos montanhosos, distorções causadas pela variação da iluminação podem comprometer tanto a acurácia da interpretação da imagem como a conversão dos números digitais (NDs) para valores de reflectância que devem ser posteriormente utilizados em índices para o estudo da umidade.

Embora o Sensoriamento Remoto ofereça grandes vantagens para o estudo de umidade do solo, o sensor ideal para esta finalidade não existe. Ele teria que

apresentar alta resolução temporal (recobrimento diário), alta resolução espacial (inferior a 10 m) e espectral (apresentando comprimentos de onda que vão do infravermelho médio às microondas). Atualmente as possibilidades de combinação entre alta resolução temporal e espacial são ainda muito caras para uma aplicação dinâmica deste estudo. Os requerimentos de resolução espacial e temporal bem com a acurácia dependem da finalidade do estudo. Este entendimento é vital para a ótima escolha do sensor e algoritmos a serem utilizados. Hoje, existem sensores remotos no infravermelho, infravermelho termal e microondas que trazem informações úteis para a detecção de umidade do solo e sua distribuição espacial.

O tema do presente trabalho é o uso do Sensoriamento Remoto voltado para o estudo da umidade do solo adotando como área de estudo uma região montanhosa. Trabalhos com esta finalidade tendem a seguir duas linhas. A primeira utiliza sensores com alta resolução temporal e conseqüentemente baixa resolução espacial, como NOAA, GOES, MODIS, etc, e gera mapeamentos regionais. A segunda utiliza o sensoriamento para a geração de mapas de fatores locais, conseqüentemente utilizam-se sensores com alta resolução espacial, porém tais estudos não são temporalmente dinâmicos.

No trabalho, a umidade do solo é estudada através da análise multitemporal de imagens multiespectrais em escala de semidetalhe e regional. Dados espectrais dos sensores Landsat ETM, ASTER e MODIS foram obtidos em diferentes tipos de solos e esta informação foi correlacionada a dados pontuais de pluviosidade através da análise multivariada. A intenção é gerar um modelo ótimo para cada sensor e que tal modelo possa contribuir na predição da umidade do solo.

Na tentativa de aprimorar os dados espectrais foram gerados índices, tais como Índices de Vegetação NDVI, Transformação Linear *Tasseled Cap* e Análise dos Componentes Principais das bandas do infravermelho, que juntamente com as demais bandas foram utilizados para a obtenção dos dados. Também foram utilizadas imagens auxiliares como imagens da Temperatura Superficial (ASTER) e Temperatura Superficial Noturna (MODIS). Dados pluviométricos foram obtidos a partir de

estações pluviométricas localizadas nos municípios de Nápoles e Salerno. Na obtenção dos modelos foram utilizadas análise discriminante, análise de regressão múltipla e redes neurais através do algoritmo GMDH.

Este trabalho apresenta inicialmente a definição do problema seguido pelo objetivo principal deste estudo, e localização da área teste. O Capítulo 2 traz uma revisão bibliográfica dos principais trabalhos que abordam o tema umidade do solo através de Sensoriamento Remoto. No Capítulo 3 é apresentada uma descrição pormenorizada dos materiais utilizados. O Capítulo 4 apresenta a metodologia adotada e os conceitos fundamentais desta metodologia. Por fim os Capítulos 5, 6, 7 e 8 apresentam os resultados obtidos e o Capítulo 9 traz a análise dos resultados e o Capítulo 10 apresenta a conclusão e recomendações.

Cabe ressaltar que este estudo foi realizado em uma província localizada na região sul da Itália, cujas características físicas e ambientais divergem grandemente das características de regiões tropicais e subtropicais. Não obstante a isso, se pode afirmar que os resultados obtidos são significativos mesmo para regiões com regimes hidrológicos distintos.

1.1 JUSTIFICATIVA

A demanda para se obter um mapa de umidade do solo em tempo real é indiscutivelmente grande há muito tempo. Do ponto de vista de monitoramento de regiões montanhosas, onde processos como movimentos de massa ocorrem freqüentemente, a possibilidade de obtenção de tais dados representaria um grande passo no sentido da predição destes eventos o que representaria um ganho socioeconômico imenso. Do ponto de vista da agricultura, isto significaria uma otimização significativa no processo de irrigação. Infelizmente até o presente momento tal predição não é possível em escala média, de 1:100.000 ou 1:50.000, por exemplo; escalas mínimas necessárias para estes estudos.

A priorização dos sensores Landsat ETM, ASTER e MODIS neste estudo se

justifica porque, embora a resolução temporal do Landsat ETM e ASTER é muito baixa para algumas medidas operacionais, como na aplicação a desastres naturais, estes sensores têm pelo menos duas vantagens sobre outros sensores: dados na região do infravermelho (bandas 5 e 7 no caso do Landsat ETM e 6 bandas no caso do ASTER) e boa resolução espacial. Além disso, no caso do ASTER, há maior resolução espectral no infravermelho termal (3 bandas com 90m de resolução). Uma boa resolução espacial reduz a incerteza na correlação com dados de campo e supri a necessidade de informações em escala de maior detalhe.

No caso do MODIS, um fator importante é sua resolução espectral, uma vez que sensores mais antigos, como o AVHRR-NOAA, apresentavam um número reduzido de bandas o que dificultava aplicações mais amplas. Além disso, tanto ASTER como MODIS apresentam produtos tais como a temperatura superficial e reflectância superficial, que são mais sensíveis à umidade.

Outro fator importante a ser considerado no estudo da umidade do solo é a variabilidade dos solos. Como a variação textural, composicional, podem comprometer disponibilidade de água no solo, o ideal para o estudo da umidade do solo seria desenvolver um modelo que pudesse caracterizar a umidade independentemente das variações texturais e composicionais dos solos.

1.2 OBJETIVO GERAL

O objetivo principal deste estudo é modelar a umidade do solo e sua distribuição espacial a partir da análise multitemporal de imagens multiespectrais em escala de semidetilhe e regional. Para isto, imagens de diferentes sensores como Landsat ETM, ASTER e MODIS, serão utilizadas.

1.3 OBJETIVOS ESPECÍFICOS

Como objetivos específicos deste estudo pode-se citar:

1. Propor modelos para a estimativa de umidade do solo baseado em

imagens dos satélites Landsat, ASTER e MODIS e avaliar a aplicação de Sensoriamento Remoto no estudo da umidade do solo em regiões montanhosas através da combinação de informação espectral derivada de imagens de satélite;

2. Comparar diferentes modelos, baseados em técnicas de análise multivariada e algoritmos de redes evolutivas;
3. Identificar o sensor que melhor se adapta para esta finalidade.

1.4 ÁREA DE ESTUDO

A área escolhida para o desenvolvimento deste trabalho situa-se na região de Campania, municípios de Nápoles e Salerno, região sul da Itália (FIGURA 1.1).

FIGURA 1.1 – LOCALIZAÇÃO DA ÁREA DE ESTUDO – REGIÃO DE CAMPANIA, ITÁLIA.



Esta área foi escolhida por ser alvo de inúmeros movimentos de massa, mais especificamente deslizamentos de terra, que ocorrem com muita frequência todos os anos, por ser bastante heterogênea do ponto de vista geomorfológico e por apresentar um número de estações pluviométricas suficiente para se elaborar um modelo estatístico a partir dos seus dados pluviométricos (20 estações foram utilizadas neste estudo), levantamentos de caracterização do solo e a disponibilidade de imagens de

satélite.

Além disso, a região da Campania apresenta uma cobertura vegetal pouco densa, que viabiliza o estudo da umidade do solo em regiões montanhosas, permitindo que fossem feitas correlações utilizando preferencialmente o solo exposto ou semi-exposto em meia vertentes, permitindo eliminar desta forma a variável vegetação neste estudo.

Segundo a classificação utilizada por DI GENNARO (2002) a região de Campania pode ser subdividida em quatro grandes sistemas: o grande sistema de montanhas, o grande sistema de colinas internas e costeiras, o grande sistema de relevo vulcânico e o grande sistema de planícies. O grande sistema de montanha corresponde à cerca de 30% do território da região de Campania e é importante do ponto de vista hidrológico, pois compreende a área de recarga de aquíferos. Seu uso é voltado preferencialmente para agricultura e floresta. O grande sistema de colinas internas e colinas costeiras representa 40% do território da região e apresenta amplo uso agrícola (cerca de 50%). O grande sistema de relevo vulcânico representa somente 6% do território da região de Campania, porém é um dos sistemas com uso da terra mais heterogêneo, correspondendo a 28% de vegetação natural, 54% de uso agrícola e o restante de extensa área urbana. O grande sistema de planícies se estende por 25% do território regional da Campania é um ambiente hidraulicamente seguro, fruto da atividade vulcânica e do relevo calcário. Compreende fundos de vale e planícies fluviais e representa 70% da área urbana da região.

Em termos geológicos a região compreende uma série calco-silicosa originada no Triássico (250 milhões de anos atrás) que se estendeu até o Jurássico (140 milhões de anos atrás), também por uma série carbonática que se desenvolveu do Triássico até o Paleoceno (65 milhões de anos atrás) e por fim por uma série vulcânica de origem Pliocênica (5,3 milhões de anos atrás) que se estende até os dias atuais. Estas litologias conjuntamente com os processos exógenos deram origem a diversos grupos de solos que serão descritas em detalhe no Capítulo 4.

2 REVISÃO DA LITERATURA

A presente revisão bibliográfica procura salientar a utilização de Sensoriamento Remoto no estudo da umidade do solo. Decorrente deste tema é apresentado uma análise de estudos no que concerne a Sensoriamento Remoto e umidade do solo; estudo da umidade do solo na faixa do visível até o infravermelho médio, estudo da umidade do solo na região termal; índices utilizados na detecção da umidade do solo; sistemas e sensores; radar e outras formas de detecção da umidade e modelagem de parâmetros físicos do solo através do Sensoriamento Remoto.

2.1 SENSORIAMENTO REMOTO E UMIDADE DO SOLO


De acordo com KITE e PIETRONIRO (1996), a umidade do solo é a porcentagem de água que está num nível da superfície da terra onde há interação com a atmosfera através da evapotranspiração. A umidade do solo pode ser entendida como um parâmetro físico que apresenta uma variabilidade espacial e temporal (NEUSCH, 1999), ao contrário de certos parâmetros como o relevo, o tipo de solo e a declividade, que só variam espacialmente. A umidade do solo é também uma propriedade física que só pode ser estimada em Sensoriamento Remoto através de métodos indiretos. Sensores remotos que atuam no infravermelho, infravermelho termal e microondas trazem informação útil para a detecção de umidade do solo.

Partindo do princípio que cada objeto possui sua assinatura espectral, ou seja, a característica do comportamento da sua reflectância em cada comprimento de onda, sabe-se que somente quando há diferença espectral entre duas superfícies no mesmo comprimento de onda é que se pode diferenciá-las adequadamente. Por isto, para a detecção da umidade do solo, deve-se entender o comportamento espectral do solo e da água em diferentes faixas do espectro eletromagnético.

O comportamento espectral do solo é mais uniforme quando comparado a outros objetos como a vegetação, por exemplo. Em termos gerais pode-se dizer que a

reflectância de um solo é maior quando se trata de solos com textura grossa, secos e sem matéria orgânica (CHUVIECO, 1990). Como se observa na FIGURA 2.1, quando há aumento de quantidade da água no solo há diminuição da reflectância. E essa diferença é mais sentida em comprimentos de onda do infravermelho próximo e médio, onde a absorção da água é maior. Por este motivo os sensores remotos que atuam infravermelho próximo e médio trazem informação útil para a umidade do solo.

FIGURA 2.1 – COMPORTAMENTO ESPECTRAL DO SOLO COM DIFERENTES TAXAS DE UMIDADE



FONTE: HOFFER (1978)

No caso do microondas esta informação é obtida através do coeficiente de dispersão (*backscattering coefficient*) associado à quantidade de água da superfície através da constante dielétrica (DOBSON *et al.*, 1985).

A estimativa de umidade em diferentes faixas espectrais é afetada por fatores como: a presença de vegetação, a topografia, a absorção atmosférica e a evapotranspiração. Alguns deles estão diretamente associados à umidade do solo e a temperatura da superfície, outros estão associados ao processo de aquisição de informações em Sensoriamento Remoto.

Nos últimos anos, autores como HOUSER (1996), KOSTER *et al.* (1999), MORENO *et al.* (1999), MULLER e DECAMP (2000), SANDHOLT, RASMUSSEN e

ANDERSEN (2002), têm utilizado Sensoriamento Remoto no estudo de parâmetros hidrológicos e, mais especificamente, no estudo da umidade do solo. Isto porque os métodos tradicionais para medir a umidade do solo são pontuais, enquanto os dados obtidos pelo sensoriamento podem ser associados a vastas áreas.

Durante a década de 90 inúmeros projetos foram desenvolvidos com a finalidade de se monitorar parâmetros hidrológicos através de Sensoriamento Remoto. Entre eles pode-se citar: o projeto Washita 92 desenvolvido na região de Oklahoma, EUA, que utilizou Sensoriamento Remoto principalmente aerotransportado e com alta resolução e o projeto Washita 94 que utilizou radar aéreo e satélite transportado para a mesma finalidade (KOSTER *et al.*, 1999). Estes projetos devido às suas amplitude geraram uma quantidade elevada dados que vêm sendo utilizados em diversos estudos da umidade do solo (CHANG e ISLAM, 2000; RODRIGUES-ITUBE *et al.*, 1995). CHANG e ISLAM (*op.cit*) utilizaram dados do Washita 92 para inferir textura do solo a partir de um estudo multitemporal da temperatura superficial.

HOUSER (1996) apresentou em sua tese de doutorado, um estudo combinado de Sensoriamento Remoto e modelos hidrológico em escala regional. Neste trabalho o autor faz uma avaliação das atuais possibilidades de utilização de sensores para o estudo da umidade do solo e concluiu que o estudo da umidade do solo em um modelo hidrológico espacialmente distribuído é possível através de Sensoriamento Remoto e que este modelo deve prever também a assimilação de dados de temperatura superficial.

Além disso, é extenso o número de estudos que buscam a identificação, não da umidade, mas da falta dela, ou seja, a identificação de seca ou facilidade ao fogo (JUSTICE *et al.*, 2002; ROY *et al.*, 2002; GOBRON *et al.*, 1999; GOBRON *et al.*, 2000, KENNEDY *et al.*, 1994; FLASSE e CECCATO, 1996). A metodologia aplicada nestes estudos é muito similar àquela aplicada no estudo da umidade do solo, pois faz uso dos mesmos comprimentos de onda utilizados para a detecção da umidade.

2.2 ESTUDO DA UMIDADE DO SOLO NAS FAIXAS DO VISÍVEL ATÉ O INFRAVERMELHO MÉDIO

O conteúdo de umidade é um dos elementos que mais afeta a reflectância de solos nos comprimentos de onda maiores (infravermelho próximo e médio), como consequência da alta absorção da água nestas bandas (CHUVIECO, 1990). O conteúdo de umidade também reduz drasticamente a reflectância da vegetação em comprimentos de onda a partir de 1.4 μm .

Uma técnica utilizada na detecção indireta da umidade do solo utiliza correlação direta entre dados de reflectância e a umidade do solo (WEIDONG *et al.*, 2002). Em seu estudo, WEIDONG *et al.* (*op.cit*) relaciona a reflectância no comprimento de onda entre (0,4 e 2,5 μm) e a umidade do solo utilizando dez tipos distintos de solo. Os resultados obtidos mostram que para níveis de baixa umidade do solo a reflectância decai enquanto a umidade do solo aumenta, por outro lado após um nível crítico, a reflectância do solo aumenta com o aumento da umidade. Este ponto crítico varia entre 0,15 a 0,4 g /cm³ dependendo do tipo de solo e é independente do comprimento de onda. Segundo estes autores, comprimentos de onda maiores são mais favoráveis para se estimar umidade do solo em baixos conteúdos de umidade e comprimentos de onda mais curtos apresentam maior correlação com umidade do solo mais alta.

Desta forma uma relação direta entre o aumento (ou diminuição) da reflectância e a umidade do solo não seria possível, reforçando a idéia de uma relação não linear.

2.3 ESTUDO DA UMIDADE DO SOLO NA REGIÃO TERMAL DO ESPECTRO ELETROMAGNÉTICO

A utilização de bandas no comprimento de onda do infravermelho termal, que vai de 8 μm a 14 μm , tem sido utilizada para estimar a umidade do solo dos primeiros centímetros através da temperatura da superfície do solo, principalmente em

função dos picos de absorção de umidade localizados nesta região.

A temperatura de superfície é modulada pela umidade de duas formas: a inércia termal do solo aumenta com o aumento da quantidade de água no solo, o que faz diminuir a fluxo de aquecimento, ou através da evapotranspiração da superfície, a água que evapora absorve o calor e reduz a mudança de temperatura. A temperatura de superfície depende também da interação com a atmosfera.

A inércia termal do solo depende da condutividade termal e da capacidade de aquecimento deste solo. A capacidade de aquecimento aumenta com o aumento do conteúdo de água, o que torna a técnica termal um método potencial para determinação da umidade do solo. Através da medida da amplitude da mudança de temperatura diurna, a habilidade do solo de resistir à mudança de temperatura pode ser estimada e a relação entre a mudança de temperatura e a umidade do solo conseqüentemente também pode ser estimada (ENGMAN, 1991).

Segundo GOETZ (1997), a temperatura superficial decai rapidamente quando atingido o que se convencionou chamar de *water-stress*, ou seja, a saturação do solo. Segundo este autor tanto a temperatura superficial (TS) como o índice NDVI oferece informações sobre as condições de umidade de superfície.

FRIEDL e DAVIS (1994) sugerem que em situações de elevada umidade, a temperatura superficial (TS) e o índice NDVI, são bons indicadores de umidade, pois são sensíveis ao aumento da inércia termal do solo.

Entre os fatores que influenciariam a umidade e conseqüentemente a temperatura superficial destaca –se:

1. a Fração de cobertura vegetal: Ela influencia na temperatura radiativa entre o solo e o *canopy* da vegetação e interfere na TS. Com o aumento da proporção de vegetação verde percebe-se que a temperatura superficial decai. Desta forma pode-se concluir que em solos expostos à radiação, a capacidade de aquecimento, que depende do tipo de solo, irá refletir na temperatura superficial em função da evapotranspiração e conseqüentemente da umidade. Assim, existe

uma alta correlação entre a umidade e a temperatura superficial (TS), o que justifica o uso das imagens de temperatura superficial na detecção da umidade do solo.

2. Evapotranspiração: Quanto menos evapotranspiração maior será a energia disponível para o aquecimento da superfície.
3. Capacidade de aquecimento e condutividade da superfície: Conseqüentemente a inércia termal influencia a TS no caso de superfícies parcialmente vegetadas. Essas propriedades termais são função do tipo de solo, e mudam com a variação da umidade do solo.

Outros estudos vêm enfatizando a importância do uso infravermelho na detecção ou pelo menos na tentativa de detecção de umidade ou falta dela (HOUSE, 1996; JUSTICE *et al.*, 2002; CHUVIECO *et al.*, 2002a, 2002b) e por isso mesmo índices como o NDII, Tasseled Cap –umidade, *Water Index* - WI (PENELAS *et al.*, 1993), o *Normalised Difference Water Index* - NDWI (GAO, 1996), o MGVI (GOBRON *et al.*, 1999) etc. tem sido criados utilizando este comprimento de onda.

2.4 ÍNDICES UTILIZADOS NA DETECÇÃO DA UMIDADE DO SOLO

Índices espectrais, entre eles índices de vegetação, são relações entre bandas, em geral na forma de diferenças e razões, utilizadas para aumentar a discriminação espectral entre objetos (LILLESAND e KIEFER, 1994). Um índice deve satisfazer alguns requisitos básicos tais como: não deve ser sensível à dispersão atmosférica e efeitos de absorção bem como as diferenças de coloração do solo e não deve ser sensível a variações temporais ou espaciais da geometria de iluminação e observação (GOBRON *et al.*, 1999).

Um dos índices mais conhecidos é o denominado índice de vegetação normalizado, resultado do contraste entre uma banda do visível (geralmente o vermelho) e uma do infravermelho próximo. Este índice tem grande aplicação no estudo da vegetação e por isto também é vastamente empregado no estudo da umidade,

como em GOETZ (1997). KOREN e KOGAN (1995) também usaram o NDVI para simular a capacidade de umidade do solo (SMC) usando o índice de vegetação NDVI com um indicador das propriedades que a afetam.

De maneira similar, outros índices podem ser propostos ou índices já conhecidos podem ser combinados com informação de outra região do espectro. Estudos têm sido feitos utilizando o NDVI, principalmente em escala global, bem como canais termais do infravermelho combinado com os índices de vegetação. Alguns bons resultados foram obtidos com o índice de deficiência de água (MORAN *et al.*, 1994), a regressão ortogonal do NDVI e a temperatura de superfície (TS). SANDHOLT, RASMUSSEN e ANDERSEN (2002) conseguiram uma elevada correlação entre dados obtidos através de imagens NOAA e dados de umidade do solo, utilizando a temperatura superficial (TS) e o índice de vegetação (NDVI) para criar um índice de secura da superfície (*Temperature - Vegetation Dryness Index*, TVDI) associado à umidade do solo.

Recentemente CHUVIECO *et al.* (2002a) apresentaram um trabalho voltado ao estudo da reflectância utilizando Landsat ETM para estimar o conteúdo de água em áreas mediterrâneas propensas a combustão para estimação de perigo de fogo. Neste trabalho imagens Landsat foram processadas e correlacionadas com o *FMC (fuel moisture content* – conteúdo de umidade de combustão) de várias espécies de gramas e arbustos mediterrâneos.

A metodologia utilizada foi:

1. As imagens originais foram convertidas para valores de reflectância e vários índices potencialmente relacionados ao conteúdo de umidade foram calculados;
2. A correlação, utilizando coeficiente de Pearson, e a análise de regressão linear múltipla foram utilizadas para se estimar o FMC.

Segundo os autores os melhores resultados obtidos foram através das derivadas das bandas 4/5 e 2/3 e a integral das bandas do visível e do infravermelho.

STORL (1994), estudou o índice de umidade (*moisture index*) desenvolvido

por MUSICK e PELLETIER (1986), a partir das razões das bandas TM5 / TM7 e concluiu que as mudanças no substrato e na cobertura vegetal limitam sua validade.

Outro índice amplamente utilizado para a detecção da umidade ou da ausência dela é o NDII, que na verdade corresponde ao índice NDVI, porém utilizando somente bandas do infravermelho.

A utilização de índices de vegetação e bandas no infravermelho próximo e médio na detecção da umidade do solo ou, estudo de áreas suscetíveis a incêndios florestais tem sido objeto de inúmeros trabalhos (HOUSER, 1996, CHUVIECO *et al.*, 2002a, 2002b). MCKEAN *et al.* (1991) apresentaram um estudo utilizando índices de vegetação no estudo da profundidade do solo e conseqüentemente na predição de movimentos de massa, mais especificamente de corridas de lama (*debris flows*). A metodologia baseia-se inicialmente na criação de um mapa de probabilidade de ocorrência de corridas de lama a partir de um modelo de regressão baseado em índices de chuva, tipos de solo, declividade e média anual de chuva. Eles selecionaram índices entre bandas a partir de suas respostas em diferentes porções do espectro, dentre eles foram utilizados a razão infravermelho próximo/ vermelho e termal/infravermelho próximo.

Segundo HUNT *et al.* (1989), o conteúdo de umidade no solo reduz a absorção nos comprimentos de onda do infravermelho médio, por isso muitos índices de vegetação utilizam bandas nesta faixa do espectro.

Outra maneira de combinar a informação de diferentes bandas em um único índice é através da aplicação de transformações espectrais, dentre as quais se destaca a denominada *Tasseled Cap*. Esta transformação foi inicialmente desenvolvida para monitorar o crescimento da vegetação a partir de dados do sensor MSS a bordo das primeiras missões do Landsat. CRIST e CICONE (1984) coletaram uma quantidade considerável de informação espectral de solo e vegetação e investigaram a aplicação da transformação *Tasseled Cap* e concluíram que, assim com para o MSS, a transformação *Tasseled Cap* para o sensor TM mostrou ser uma valiosa ferramenta, no que se refere à redução de dados, bem como na melhora da interpretabilidade.

Outros a utilizarem a transformação *Tasseled Cap* foram HEJMANOWSKA e MULARZ (2000) que estudaram a umidade do solo através da fusão de imagens de radar (ERS) de diferentes períodos com imagens LANDSAT. Neste trabalho, a técnica da fusão de imagens provenientes de diferentes sensores foi utilizada para se melhorar a definição de categorias como uso e ocupação do solo. Os autores também desenvolveram um método chamado de Método da Inércia Termal, que se mostrou efetivo para a avaliação da umidade do solo. Este método combina informação proveniente de bandas do visível com o infravermelho termal. Neste modelo torna-se necessário conhecer o albedo e a diferença de temperatura máxima do dia da aquisição da cena. O albedo foi obtido através da Banda TM 3 e a diferença de temperatura máxima através da TM 6.

CHUVIECO *et al.* (2002a, 2002b) utilizaram dados obtidos com a transformação *Tasseled Cap*- banda umidade, derivadas e integrais de bandas espectrais para estimar o índice de água do combustível vivo de em áreas Mediterrâneas na estimação do perigo a incêndios florestais. Os resultados mostraram que para áreas onde predominavam a ocorrência de grama, a integral de bandas do visível e do infravermelho foi o índice que apresentou a correlação a mais elevada. Para as espécies arbóreas a reflectância direta das bandas e os índices utilizando bandas do infravermelho tiveram um desempenho melhor do que NDVI.

2.5 SISTEMAS E SENSORES

Ao avaliar sensores para a detecção de umidade uma das características principais a ser observada é a alta definição temporal, espacial e espectral porque as características da umidade mudam em períodos curtos e localmente. Em termos de resolução espectral, os sensores com boa resolução no infravermelho próximo e médio (incluindo as bandas termais) são os mais indicados. Em termos práticos, o uso de imagens de sensores de alta resolução espacial, como o IKONOS ou Quickbird fica restrito em função do alto custo para se obter imagens com adequada resolução

temporal. Por este motivo, a presente à discussão concentra-se nos sistemas de média e baixa resolução espacial, como o AVHRR-NOAA, Landsat, MODIS e ASTER.

O sistema ideal teria alta resolução temporal, pois assim permitiria monitorar as variações temporais da umidade. Nesta linha os sensores AVHRR, MODIS e Meris são opções interessantes devido à sua alta resolução temporal.

São muitos os estudos que utilizam o sensor AVHRR (*Advanced Very High Resolution Radiometer*), do NOAA, na estimação da umidade devido à sua alta resolução temporal, porém a desvantagem deste sensor é a sua baixa resolução espacial (da ordem de 1km). O AVHRR também tem sido amplamente usado em estudos regionais para a detecção de focos de incêndio (KENNEDY *et al.*, 1994; FLASSE e CECCATO, 1996) através de alguns índices como o NDVI, e também através da Temperatura de Superfície obtida a partir das suas bandas térmicas (PRATA *et al.*, 1995).

Devido à combinação de alta resolução temporal com alta resolução espectral, sensores como o MODIS e Meris têm despertado a atenção dos cientistas no estudo de conteúdo de água da vegetação, detecção de fogo e análise da detecção de mudanças (JUSTICE *et al.*, 2002.; ROY *et al.*, 2000; GOBRON *et al.*, 1999).

Embora os sensores como Landsat ETM e ASTER tenham baixa resolução temporal eles têm como vantagem uma boa definição espectral e espacial que permite uma correlação mais precisa com dados de campo. A aplicabilidade de tais sensores é apresentada por JUSTICE *et al.* (*op.cit*) e CHUVIECO *et al.* (2002a, 2002b).

2.6 RADAR E OUTRAS FORMAS DE DETECÇÃO DA UMIDADE

A aplicação de imagens correspondentes à faixa das microondas na detecção da umidade é amplamente aceita. Imagens de radar (*Syntetic Aperture Radar* - SAR) permitem detectar diferenças da umidade do solo devido ao seu efeito de retroespalhamento (*back scattering*), que é fortemente dependente da quantidade de água presente (DUBOIS e ENGMAN, 1995; WAGNER, 1988).

Estudos como os de LU e MEYER (2002), ROMBACH e MAUSER (2002), MORAN *et al.* (2002), têm mostrado que o comprimento de onda mais adequado para o estudo da umidade do solo é a faixa das microondas. Isto porque nesta região espectral é viável estudar a constante dielétrica do solo e da água, que neste comprimento de onda são extremamente diferentes, o que permite identificar solos com variáveis conteúdos de água. Segundo estes autores, usando sensores ativos na faixa das microondas, a umidade do solo pode também ser diretamente relacionada ao coeficiente de dispersão para a identificação dos 5 cm iniciais da umidade do solo.

A faixa das microondas tem sido utilizada na detecção da umidade do solo devido à sua alta capacidade de penetração e a possibilidade de detecção, através deste comprimento de onda, da constante dielétrica do solo e da água. Entre os principais sensores utilizados destaca-se o ERS-1 e ERS-2 (HEJMANOWSKA e MULARZ, 2000) e sensores aerotransportados.

Um ponto desfavorável da utilização de radar no estudo da umidade do solo quando este é voltado para movimentos de massa é que em terrenos acidentados (com vertentes superiores a 15-20°) o sinal obtido pelo radar é deteriorado.

2.7 MODELAGEM DE PARÂMETROS FÍSICOS DOS SOLOS ATRAVÉS DE SENSORIAMENTO REMOTO

Diversas têm sido as formas de análise de dados espectrais para a modelagem de modelos de predição, sendo a análise temporal de imagens a técnica mais empregada na obtenção de dados (CHANG e ISLAM, 2000; MORAN *et al.*, 2002; CHUVIECO *et al.*, 2002a, 2002b; MCKEAN *et al.*, 1991), pois ela permite modelar a variabilidade presente em dados provenientes de períodos distintos como, por exemplo, a modelagem da variação sazonal.

Para a modelagem de fenômenos naturais a partir de imagens de satélite, é geralmente utilizada a abordagem estatística através de análise multivariada. Dentre tipos de análise mais freqüentemente utilizados destacam-se a análise discriminante e a

regressão múltipla (WALSH e BUTLER, 1997; CHUVIECO *et al.*, 2002a; FIORIO *et al.*, 2003). Outra opção é o uso de técnicas de inteligência artificial, como as redes neurais (CHANG e ISLAM, 2000; RIBEIRO, 2003; KISHI, 2001).

A análise de regressão, por exemplo, é muito utilizada no estudo de parâmetros físicos de solos. FIORIO *et al.* (2003) utilizaram regressões lineares múltiplas para modelar dados espectrais obtidos em laboratório e por sensores orbitais (Landsat 5) para estimar a porcentagem de Fe_2O_3 no solo. Segundo os autores os valores obtidos com a regressão conseguiram explicar mais de 90% da variabilidade dos dados.

CHANG e ISLAM (2000) utilizaram dados do experimento Washita 92 para inferir, a partir de dados multitemporais de temperatura, a textura do solo usando microondas passivo, constataram que há uma relação grande entre a evolução espaço-tempo da temperatura, umidade do solo e tipo do solo.

WALSH e BUTLER (1997) utilizaram análise dos componentes principais para determinar algumas variáveis morfométricas que explicam a variação de posição de corridas de lama (*debris flows*) e fizeram uso da análise de regressão multivariada para relacionar a presença ou ausência de corridas de lama em um grupo de medidas espectrais.

MCKEAN *et al.* (1991), também criaram um mapa de probabilidade de ocorrência de corridas de lama a partir de um modelo de regressão baseado em índices de chuva, tipos de solo, declividade e média anual de chuva.

A utilização de redes neurais na modelagem de dados e especialmente na predição de comportamento de parâmetros físicos e ambientais tem sido grande nos últimos anos, isto porque esta permite que se realize a modelagem sem um conhecimento profundo das relações entre as variáveis independentes (preditoras) e a variável dependente (a ser prevista). Exemplos de aplicação podem ser encontrados em CHANG e ISLAM (2000), KISHI (2001) e RIBEIRO (2003).

3 MATERIAIS

Neste estudo foram utilizados dados espectrais dos sensores Landsat ETM, ASTER e MODIS, medições de campo e outros materiais descritos a seguir:

Imagens Digitais

1. Imagem Landsat ETM, todas as bandas, adquirida em 28 de novembro de 2002.
2. Duas imagens MODIS de reflectância de superfície, bandas 1 a 7, e também a temperatura superficial noturna (TSN) adquiridas 06 de abril de 2002 e 23 de abril de 2002.
3. Seis imagens ASTER de reflectância de superfície (AST07) e temperatura superficial (AST05) adquiridas em 26 de setembro de 2000, 25 de junho de 2001, 20 de julho de 2001, 28 de janeiro de 2002, 20 de maio de 2002 e 17 de agosto de 2002.
4. Dois Modelos Digitais do Terreno relativos (AST14) gerados a partir das imagens ASTER adquiridas em 25 de junho de 2001 e 28 de janeiro de 2002

Mapas Impressos e Dados Pluviométricos

1. Mapa Topográficos em 1:50.000 de Nápoles (folha 449), Herculano (folha 448), Sorrento (folha 458) e Salerno (folha 457).
2. Mapa Geológico em 1:100.000 de Nápoles (folha 186), Salerno (folha 185) e Eboli (folha 198).
3. Mapa Sistema da Terra da região de Campania, 1:250.000
4. Dados pluviométricos das estações pluviométricas: Acerra, Agropoli, Altavilla Silentina, Baccoli, Baronissi, Battipaglia, Buccino, Buonabitacolo, Casalvelino, Castel S.Lorenzo, Giugliano, Giugliano L, Gromola, Mirabella, Montella, S.Marzano, Striano, Terzigno e Villaricca, nos municípios de Nápoles e Salerno, região de Campania.

Programas

1. ENVI
2. MATLAB
3. Statgraph
4. PCI

3.1 RECOBRIMENTO DAS IMAGENS

As Imagens Digitais utilizadas neste estudo apresentam o seguinte recobrimento em relação às estações pluviométricas:

- **Imagem Landsat:** Acerra, Altavilla Silentina, Baronissi, Battipaglia, Buccino, Buonabitacolo, Casalvelino, Castel S.Lorenzo, Giugliano, Giugliano L, Gromola, Mirabella, Montella, S.Marzano, Striano, Terzigno, Villaricca.
- **Imagem ASTER de 26 de setembro de 2000:** Acerra, Giugliano L, S.Marzano, Striano, Terzigno, Villaricca.
- **Imagem ASTER de 25 de junho de 2001:** Acerra, Baronissi, Battipaglia, Mirabella, Montella, S.Marzano, Striano.
- **Imagem ASTER de 20 de julho de 2001:** Buccino, Buonabitacolo, Casalvelino.
- **Imagem ASTER de 28 de janeiro de 2002:** Baronissi, Battipaglia, Castel S.Lorenzo, Gromola, S.Marzano, Terzigno.
- **Imagem ASTER de 20 de maio de 2002:** Agropoli, Baronissi, Castel S.Lorenzo, Gromola.
- **Imagem ASTER de 17 de agosto de 2002:** Altavilla Silentina, Buccino, Castel S.Lorenzo.
- **Imagem MODIS de 06 de abril de 2002:** Acerra, Agropoli, Altavilla Silentina, Baronissi, Battipaglia, Castel S.Lorenzo, Giugliano, Giugliano L, Gromola, Mirabella, Montella, S.Marzano, Striano, Terzigno, Villaricca

- **Imagem MODIS de 23 de abril de 2002:** Acerra, Agropoli, Altavilla Silentina, Baronissi, Battipaglia, Castel S.Lorenzo, Giugliano, Giugliano L, Gromola, Mirabella, Montella, S.Marzano, Striano, Terzigno, Villaricca.


3.2 IMAGENS ASTER– ADVANCED SPACEBORNE THERMAL EMISSION AND REFLECTANCE RADIOMETER

O Satélite TERRA (NASA) responsável pela produção das imagens ASTER é provido de três telescópios diferentes: o primeiro que gera três bandas na região do visível e infravermelho próximo com 15m de resolução; um segundo responsável pelos dados de seis bandas no infravermelho médio com 30m de resolução e um telescópio com cinco bandas no infravermelho termal com 90m de resolução (TABELA 3.1, FIGURA 3.1).

TABELA 3.1 - BANDAS DO SENSOR ASTER, SATÉLITE TERRA - NASA


	Bandas	Comprimento de Onda (γ)	Resolução Espacial
Visível e infravermelho próximo (VNIR)	VNIR1	0.52 – 0.60 μ m	15m
	VNIR2	0.63 - 0.69 μ m	
	VNIR3N*	0.78 – 0.86 μ m	
Infravermelho (SWIR)	SWIR1	1.6 – 1.7 μ m	30m
	SWIR2	2.145 – 2.185 μ m	
	SWIR3	2.185 – 2.225 μ m	
	SWIR4	2.235 – 2.285 μ m	
	SWIR5	2.295 – 2.365 μ m	
	SWIR6	2.360 – 2.430 μ m	
Infravermelho Termal (TIR)	TIR1	8.125 – 8.475 μ m	90m
	TIR2	8.475 – 8.825 μ m	
	TIR3	8.925 – 9.275 μ m	
	TIR4	10.25 – 10.95 μ m	
	TIR5	10.95 – 11.64 μ m	

FIGURA 3.1 - BANDAS ESPECTRAIS DO SENSOR ASTER, NO ESPECTRO ELETROMAGNETICO.



Uma característica interessante deste satélite é que a banda no infravermelho – próximo (VNIR3) é adquirida em dois telescópios, um no nadir e outro com uma diferença de 27.6° para trás (VNIR3N – “back”) e desta forma pode-se obter imagens em estéreo para a geração de modelos digitais do terreno (FIGURA 3.2).

FIGURA 3.2 - DIFERENÇA ANGULAR NA AQUISIÇÃO DAS 2 BANDA DO INFRAVERMELHO PRÓXIMO



As imagens ASTER apresentam pelo menos três vantagens para este estudo: boa resolução espacial no visível e infravermelho (15m e 30m), possibilidade de gerar o modelo digital do terreno e alta resolução espectral tanto no infravermelho médio como no infravermelho termal.

Neste estudo ao invés de se utilizar às imagens originais optou-se em utilizá-la já convertidas para a reflectância de superfície. Além das imagens de reflectância de superfície, foram utilizadas as imagens correspondentes à temperatura superficial e os índices gerados a partir das imagens de reflectância de superfície.

3.2.1 Reflectância da Superfície

Foram utilizadas imagens de reflectância de superfície (AST07), já processadas, nas três bandas do visível e infravermelho próximo -VNIR com 15 metros de resolução e nas seis bandas do infravermelho médio - SWIR com 30 metros de resolução. Estas imagens sofreram correção atmosférica e conversão para radiância. As correções atmosféricas removem os efeitos causados pela geometria satélite-sol e pelas condições atmosféricas. As imagens de reflectância de superfície (AST07)

apresentam acurácia absoluta de 0,01 para reflectâncias inferiores a 0,15 e de 7% para reflectância superiores a este valor. A acurácia relativa é igual a 0,005 (THOME, 1999).

A correção atmosférica, aplicada às imagens AST07, é utilizada para se obter a reflectância de superfície através da LUT (*Look-up table*). A LUT contém valores de transferência de radiação calculados a partir da interação Gauss-Seidel. Isso permite que se calcule a radiação do satélite para um grupo de valores de reflectância de superfície e uma variedade de condições atmosféricas. A correção atmosférica é então aplicada utilizando-se como entrada um grupo de condições atmosféricas relacionadas com a cena ASTER de interesse e esta cena é separada na LUT. A saída da LUT é um grupo de pares: reflectância de superfície /radiância do sensor (THOME, 1999). Através de interpolação linear aplicada a estes pares a radiância obtida pelo ASTER é convertida em reflectância de superfície. As condições atmosféricas são dadas pelo tipo de aerossol, sua quantidade, pressão de superfície, geometria sol-satélite. A informação sobre aerossol é obtida por fontes externas tais como imagens MODIS, MISR etc.

Como resultado são obtidos valores dos números digitais que correspondem a valores de reflectância variando entre 0 e 1.

3.2.2 Temperatura de Superfície (TS)

Assim como as imagens de reflectância de superfície, as imagens referentes à temperatura de superfície (AST05) também são pré-processadas. Estas imagens apresentam uma resolução espacial de 90 metros e são geradas a partir das cinco bandas termais. Suas unidades são graus Kelvin e apresentam acurácia absoluta entre 1 a 4 K e acurácia relativa de 0,3 Kelvin e são calculadas a partir da lei de Planck que determina a temperatura de superfície a partir da emissividade (GILLESPIE *et al.*, 1999).

3.3 MODIS - MODERATE RESOLUTION IMAGING SPECTRORADIOMETER

Em dezembro de 1999, a NASA lançou o satélite Terra em órbita polar, sol-sincrônica a 705 quilômetros de altitude. Entre os sensores incluídos neste satélite, além do ASTER mencionado no item anterior, encontra-se o MODIS *Moderate Resolution Imaging Spectroradiometer*.

O MODIS está também a bordo do satélite Aqua, desta forma são adquiridas imagens no modo descendente (satélite Terra), às 10h30, ou no modo ascendente (satélite Aqua) às 13h30. Este dois satélites juntos fazem o recobrimento total da Terra a cada 1 a 2 dias, adquirindo imagens em 36 bandas. Destas 36 bandas do sensor MODIS as duas primeiras apresentam resolução espacial de 250 metros, da banda 3 a banda 7 a resolução espacial é de 500 metros e a partir da banda 8 a resolução é de 1 km. A TABELA 3.2 apresenta o uso primário de cada banda, seu comprimento de onda e sua radiância espectral.

TABELA 3.2 – BANDAS DO SENSOR MODIS, SATELITE TERRA - NASA

Uso Primário	Bandas	Comprimento de Onda (γ)	Radiância Espectral ²	Resolução Espacial
Terra/ Nuvens/ Aerossol	M1	0.62 – 0.67 μ m	21,8	250m
	M2	0.84 - 0.87 μ m	24,7	
	M3	0.45 – 0.47 μ m	35,3	
	M4	0.54 – 0.56 μ m	29,0	
Terra/ Nuvens/ Aerossol	M5	1.23 – 1.25 μ m	5.4	500m
	M6	1.62 – 1.65 μ m	7.3	
	M7	2.10 – 2.15 μ m	1.0	
	M8	0.40 – 0.42 μ m	44.9	
	M9	0.43 – 0.44 μ m	41.9	
	M10	0.48 – 0.49 μ m	32.1	
	M11	0.52 – 0.53 μ m	27.9	1000m
	M12	0.54 – 0.55 μ m	21.0	
	M13	0.66 – 0.67 μ m	9.5	
	M14	0.67 – 0.68 μ m	8.7	
	M15	0.74 – 0.75 μ m	10.2	
	M16	0.86 – 0.87 μ m	6.2	
	M17	0.89 – 0.92 μ m	10.0	
	M18	0.93 – 0.94 μ m	3.6	
	M19	0.91 – 0.96 μ m	15.0	
	M20	3.66 – 3.84 μ m	0.45(300K)	
	M21	3.92 – 3.98 μ m	2.38(335K)	
	M22	3.92 – 3.98 μ m	0.67(300K)	
	M23	4.02 – 4.08 μ m	0.79(300K)	
	M24	4.43 – 4.49 μ m	0.17(250K)	
	M25	4.48 – 4.54 μ m	0.59(275K)	
	M26	1.36 – 1.39 μ m	6.00	

M27	6.53 –6.89 μ m	1.16(240K)
M28	7.17 –7.47 μ m	2.18(250K)
M29	8.4 –8.7 μ m	9.58(300K)
M30	9.58 –9.88 μ m	3.69(250K)
M31	10.78 –11.28 μ m	9.55(300K)
M32	11.77 –12.27 μ m	8.94(300K)
M33	13.18 –13.48 μ m	4.52(260K)
M34	13.48 –13.78 μ m	3.76(250K)
M35	13.78 –14.08 μ m	3.11(250K)
M36	14.08 –14.38 μ m	2.08(220K)

² Valores de Radiância Espectral estão em (W/m²- μ m-sr).

FONTE: <http://MODIS.gsfc.nasa.gov/about/specs.html>

3.3.1 Reflectância da Superfície

As imagens de reflectância de superfície utilizadas referem-se às bandas 1 a 7 e assim como as imagens ASTER também são pré-processadas. O algoritmo aplicado nestas imagens corrige os efeitos de dispersão causados por aerossol (dispersão e absorção) bem como causados por efeitos adjacentes oriundos da variação do cobertura do terreno (VERMOTE e VERMEULEN, 1999).

3.3.2 Temperatura Superficial Noturna (TSN)

Neste estudo foram utilizadas imagens da Temperatura Superficial Noturna, em sua versão 3.3 baseadas no algoritmo de WANG e LI (1997), que foi especialmente desenhado para o instrumento MODIS. Este algoritmo foi validado por dados de campo adquiridos entre 1996-1998 (WANG *et al.*, 1998).

A temperatura de superfície é obtida a partir das bandas termais e apresenta em média 1°K de acurácia em 1 km de resolução espacial.

A assinatura de infravermelho termal recebida pelo sensores do satélite é determinada pela temperatura superficial, pela emissividade superficial, pela reflectividade e emissão atmosférica, e pela absorção termal a partir da radiação de superfície. Um banco de dados foi criado para gerar os valores de radiância das bandas termais do MODIS, a partir de simulações considerando uma ampla gama de condições atmosféricas e de superfície.

3.4 LANDSAT ETM+

Landsat 7 ETM+ é o último satélite da série Landsat que se iniciou em 1972 com o scanner multiespectral MSS. Landsat 2 e 3 foram lançados em 1975 e 1978 respectivamente e apresentavam configuração similar. Em 1984 foi lançado o Landsat 4 com um novo instrumento, o Thematic Mapper (TM). Entre outras melhoras este instrumento apresentava melhora na resolução espacial, que de 80m passou para 30m e apresentou três novas bandas.

O Landsat 5 foi lançado em 1984 e apresentou estrutura similar ao Landsat 4. O Landsat 6, lançado em 1993 apresentava entre outros aprimoramentos uma banda com resolução de 15m, porém este satélite foi perdido imediatamente após seu lançamento. A TABELA 3.3 traz a cronologia e as principais diferenças entre os satélites Landsat e a TABELA 3.4 traz a descrição das bandas do Landsat 7.

TABELA 3.3 – CARACTERÍSTICAS DAS MISSÕES LANDSAT

Sistema	Lançamento	Instrumento	Resolução Espacial (m)	Altitude (km)	Resolução Temporal (dias)
Landsat 1	23/07/72 a 06/01/78	RBV MSS	80	917	18
Landsat 2	22/01/75 a 25/02/82	RBV MSS	80	917	18
Landsat 3	05/03/78 a 31/03/83	RBV MSS	30 80	917	18
Landsat 4	16/07/82 a 1993	MSS TM	80 30	705	16
Landsat 5	01/03/84	MSS TM	80 30	705	16
Landsat 6	05/10/93 a 05/10/93	ETM	15 (pan) 30	705	16
Landsat 7	04/99	ETM+	15 (pan) 30	705	16

FONTE: IRISH (2000)

TABELA 3.4 - BANDAS DO LANDSAT 7 ETM+

Bandas	Comprimento de onda (γ)	Resolução Espacial (m)
1	0.45 – 0.52 μ m	30m
2	0.52 - 0.60 μ m	
3	0.63 – 0.69 μ m	
4	0.76 – 0.90 μ m	
5	1.55 – 1.75 μ m	60m
6	10.4 – 12.5 μ m	
7	2.08 – 2.35 μ m	30m
PAN	0.50 – 0.90 μ m	15m

FONTE: IRISH (2000)

4 MÉTODOS

4.1 DESCRIÇÃO GERAL DOS MÉTODOS APLICADOS

O estudo da umidade do solo através de Sensoriamento Remoto é um método de análise indireta. Para que os dados espectrais reflitam o parâmetro físico, no caso umidade, procura-se isolar alguns fatores que poderiam interferir na resposta espectral, como é o caso do tipo de solo. Além disso, as imagens de satélite sofrem outros tipos de interferências que devem ser eliminadas como os efeitos causados pela atmosfera e os efeitos da iluminação causados pelo relevo.

Neste estudo todas imagens foram convertidas para valores de reflectância e os índices utilizados em algumas delas foram gerados a partir destes valores.

Em linhas gerais, o método pode ser dividido em quatro fases distintas:

1. Primeira Fase - processamento das imagens;
2. Segunda Fase - obtenção de dados de verdade de campo;
3. Terceira Fase - correlação entre acumulado de chuvas e os dados espectrais: critérios para escolha das análises;
4. Quarta Fase – testes de verificação dos resultados.

4.2 PRIMEIRA FASE: PROCESSAMENTO DAS IMAGENS

A escolha dos sensores Landsat, ASTER e MODIS foi justificada no Capítulo 3. Ela atende a necessidade de conhecimento da resposta espectral destes sensores em relação à umidade do solo. Por conterem características de resolução espectral e espacial diferentes (Capítulo 3) e por este estudo fazer uso de alguns produtos já pré-processados, como é o caso das imagens de reflectância e temperaturas superficiais, ASTER e MODIS, o método de pré-processamento aplicado é diferente para cada sensor. No caso das imagens ASTER e MODIS o único pré-processamento aplicado foi o georeferenciamento das imagens. A imagem Landsat passou por georeferenciamento, correção atmosférica e correção dos efeitos da iluminação solar.

4.2.1 Georreferenciamento das Imagens

Para o registro de todas as imagens foi utilizada a projeção UTM, zona 33 Norte e datum Europeu 1950.

O registro da imagem pode ser subdividido em duas etapas. A primeira é a estimativa do modelo de transformação geométrica e a segunda é a geração da imagem, com a conseqüente reamostragem, onde se determina o valor do pixel na nova imagem a partir dos valores presentes na imagem original.

No modelo de transformação de coordenadas utiliza-se geralmente transformações polinomiais. No presente trabalho utilizou-se a transformação polinomial de primeira ordem, dada pelas equações genéricas (4.1) e (4.2):

$$x' = a_0 + a_1x + a_2y \quad (4.1)$$

$$y' = d_0 + d_1x + d_2y \quad (4.2)$$

Esta transformação exige no mínimo 3 pontos de controle para a resolução do sistema. Foram utilizados dezoito pontos de controle para a imagem Landsat de 2002 e o RMS "*Root Mean Square Error*" obtido foi de 0,33 pixel. Para as imagens ASTER foram utilizados vinte pontos de controle com RMS de 0,3 e para as imagens MODIS foram utilizados doze pontos com RMS de 0,7 pixel. Em todos os casos o RMS foi inferior a 1 pixel, o que permite um resultado preciso na obtenção das medidas espectrais.

O método de reamostragem utilizado foi o do vizinho mais próximo. Neste método todo pixel na imagem registrada recebe o nível de cinza do pixel mais próximo na imagem original. Tem como vantagens a preservação dos níveis de cinza originais, um processamento rápido e uma implementação fácil, porém, como desvantagem apresenta a ocorrência de descontinuidades geométricas da ordem de 1/2 pixel na imagem corrigida. A escolha deste método se justifica principalmente pelo fato dele preservar o valor original dos números digitais, ou seja, de manter-se os valores originais do contador digital, o que não altera o valor espectral de medidas pontuais.

4.2.2 Pré-Processamento das Imagens Landsat

O método utilizado para o tratamento das imagens Landsat é similar ao apresentado por MAFFRA e CENTENO (2002) e CHUVIECO *et al.* (2002a). Ele consiste basicamente na correção atmosférica e posteriormente conversão dos números digitais para reflectância. Como inicialmente notou-se que algumas imperfeições eram decorrentes deste processo como, por exemplo, obter uma fração mínima de reflectâncias negativas, optou-se fazer inicialmente a conversão dos números digitais (NDs) para reflectância e posteriormente remover os efeitos da atmosfera.

4.2.3 Conversão dos NDs para valores de reflectância

Sabe-se que para estudos multitemporais e de correlação com variáveis físicas, no caso umidade do solo, um importante aspecto é eliminar variáveis que possam influir nos valores dos números digitais das imagens, como por exemplo, os efeitos atmosféricos. Segundo HUANG *et al.* (2001) há três formas de se normalizar os impactos da atmosfera e da iluminação. O primeiro é através da correção atmosférica utilizando algoritmos (mas para isso muitas vezes se necessita dados de campo). O segundo é através dos chamados objetos *pseudo-invariantes*, que a técnica aplicada por CHAVEZ (1996). Neste método se utiliza um objeto cujas propriedades espectrais variam muito pouco em diferentes períodos de aquisição como, água profunda, e tomam-se estes valores como base para a correção de toda a cena. A última opção é a conversão dos valores dos números digitais para valores de reflectância.

MARKHAM e BARKER (1986) sugerem duas equações para conversão das imagens para valores de reflectância sem a prévia correção dos impactos da topografia e da atmosfera, porém com já abordado em outros trabalhos (SANDMEIER, 1995; HILL e MEHL, 1995; PARLOW, 1996) o impacto da topografia e da atmosfera altera em muito os valores dos NDs e conseqüentemente dos valores de reflectância.

A transformação dos números digitais (NDs) para valores de reflectância foi feita com base nas equações fornecidas por MARKHAM e BARKER (1986) e pelos

dados obtidos no *Landsat Science Data Users Handbook* (IRISH, 2000) para Landsat 7 ETM.

Conversão de NDs para radiância, segundo IRISH (*op.cit*), pode ser feita através da equação (4.3) ou equação (4.4).

$$R = \text{gain} * \text{ND} + \text{offset} \quad (4.3)$$

ou

$$R = ((L_{\max} - L_{\min}) / (QCaL_{\max} - QCaL_{\min})) * (QCaL - QCaL_{\min}) + L_{\min} \quad (4.4)$$

onde

$$QCaL_{\min} = 1$$

$$QCaL_{\max} = 255$$

$$QCaL = \text{Número Digital (ND)}.$$

De acordo com a localização da área de estudo L_{\max} e L_{\min} devem ser calculados como: Banda_1= *low gain*, Banda_2= *low gain*, Banda_3= *low gain*, Banda_4= *high gain*, Banda_5= *high gain*, Banda_7= *high gain* (TABELAS 4.1 e 4.2).

TABELA 4.1 – RADIÂNCIA PARA BANDAS ESPECTRAIS ETM ($W/M^2 * \mu M$)

bandas	Antes de 1° Julho, 2000				Depois de 1° julho, 2000			
	Low gain		High Gain		Low gain		High gain	
	L_{\min}	L_{\max}	L_{\min}	L_{\max}	L_{\min}	L_{\max}	L_{\min}	L_{\max}
1	-6.2	297.5	-6.2	194.3	-6.2	293.7	-6.2	191.6
2	-6.0	303.4	-6.0	202.4	-6.4	300.9	-6.4	196.5
3	-4.5	235.5	-4.5	158.6	-5.0	234.4	-5.0	152.9
4	-4.5	235.0	-4.5	157.5	-5.1	241.1	-5.1	157.4
5	-1.0	47.70	-1.0	31.76	-1.0	47.57	-1.0	31.06
6	0.0	17.04	3.2	12.65	0.0	17.04	3.2	12.65
7	-0.35	16.60	-0.35	10.932	-0.35	16.54	-0.35	10.80
8	-5.0	244.00	-5.0	158.40	-4.7	243.1	-4.7	158.3

Fonte: Landsat Science Data Users Handbook (IRISH, 2000)

TABELA 4.2 - VALORES DE GAIN PARA ÁREA EM ESTUDO, NOVEMBRO DE 2002

Banda	L_{\min}	L_{\max}	$L_{\max} - L_{\min}$
1	-6.2	293.7	299.7
2	-6.4	300.9	307.3
3	-5.0	234.4	239.4
4	-5.1	157.4	162.5

5	-1.0	31.06	32.06
6	3.2	12.65	9.45
7	-0.35	11.15	10.8

Reflectância é então calculada através da equação (4.5):

$$R = \pi * \text{radian} * k / Esun * \sin(\theta) \quad (4.5)$$

onde:

k = fator corretor da distância Terra - Sol

$Esun$ = irradiância extraterrestre para cada banda Landsat 7

θ = ângulo de incidência

sendo k calculado pela expressão (4.6):

$$k = 1 + 0.0167 (\sin \pi(2(\text{dia} - 93.5)/365))^2 \quad (4.6)$$

Os valores de $Esun$ estão expressos na TABELA 4.3.

TABELA 4.3 - IRRADIÂNCIA ESPECTRAL SOLAR PARA LANDSAT 7 ($W/M^2 \cdot \mu M$)

Banda	$Esun$
Banda 1	1969.00
Banda 2	1840.00
Banda 3	1551.00
Banda 4	1044.00
Banda 5	225.70
Banda 7	82.07

FONTE: Landsat Science Data Users Handbook (IRISH, 2000)

4.2.4 Índices e Bandas Utilizados para cada Sensor

Com a finalidade de reduzir o número de bandas e aproveitar a informação contida nos índices espectrais, as bandas dos sistemas Landsat, MODIS e ASTER foram combinadas sob forma de índices ou aplicando transformações espectrais conhecidas.

Para as imagens ASTER também foram utilizadas as adaptações dos índices de vegetação NDVI e NDII e do Tasseled Cap – umidade. No caso do Landsat optou-se por avaliar o comportamento dos índices de vegetação NDVI e NDII; dos

componentes principais das bandas do infravermelho (ETM5 e ETM7) e da banda umidade da transformação Tasseled Cap, como indicaram estudos preliminares (MAFFRA e CENTENO, 2002). Para as imagens ASTER e MODIS foram utilizadas a reflectância superficial e temperatura superficial, assim as correlações destas imagens foram feitas diretamente com os valores de reflectância e temperatura obtidos de cada banda.

4.2.4.1 Índices de Vegetação

Índices de vegetação podem ser entendidos como operações matemáticas entre bandas que tem por finalidade aumentar o contraste dos valores espectrais a fim de facilitar a identificação de determinados objetos (LILLESAND e KIEFER, 1994). Há dois índices de vegetação mais conhecidos que foram inicialmente calculados a partir das combinações dos canais 1 e 2 dos sensores do AVHRR, eles são o Índice de Vegetação VI (*Vegetation Index*), propriamente dito, e o Índice de Vegetação Normalizado NDVI (*Normalised Difference Vegetation Index*). Eles são calculados a partir das seguintes equações (4.7) e (4.8).

$$VI = Ch_2 - Ch_1 \quad (4.7)$$

$$NDVI = (Ch_2 - Ch_1) / (Ch_2 + Ch_1) \quad (4.8)$$

onde Ch_1 e Ch_2 correspondem respectivamente às bandas 1 e 2 do AVHRR

Atualmente estes índices são utilizados com bandas do LANDSAT ETM; a banda Ch_1 é substituída pela banda ETM4 e a banda Ch_2 pela banda ETM3, respectivamente as bandas correspondentes ao infravermelho próximo e ao vermelho. Estas bandas foram escolhidas porque é exatamente nestas regiões do espectro eletromagnético que a vegetação apresenta maior diferença de reflectância (elevada reflectância no infravermelho e baixa reflectância no vermelho).

O NDVI é utilizado para acentuar outras feições e não somente a vegetação, como é observado em MCKEAN *et al.* (1991), que utilizou este índice no estudo da

determinação de áreas mais suscetíveis a movimentos de massa.


Um outro índice de vegetação muito utilizado para o estudo da umidade é o NDII *Normalised Difference Infrared Index*, HUNT e ROCK, (1989). O NDII é uma variante do NDVI, porém utiliza ao invés da banda do vermelho (ETM3) a banda do infravermelho médio (ETM5), equação (4.9).

$$\text{NDII} = (\rho_{\text{nir}} - \rho_{\text{swir}}) / (\rho_{\text{nir}} + \rho_{\text{swir}}) \quad (4.9)$$

onde ρ_{nir} e ρ_{swir} correspondem respectivamente às bandas ETM4 e ETM5 do Landsat.

A FIGURA 4.1 mostra exemplos dos índices NDVI e NDII para o Landsat 7 em uma das estações pluviométricas da área em estudo.

FIGURA 4.1 – EM A: NDVI E EM B: NDII, EM 3D PARA A ESTAÇÃO PLUVIOMÉTRICA DE ACERRA, COM EXAGERO VERTICAL DE 2.0 EM AMBAS FIGURAS.



A - NDVI

B – NDII

Para as imagens ASTER calculou-se os índices NDVI e NDII, utilizando as bandas do visível e infravermelho próximo (VNIR) VNIR2 e VNIR3, substituindo as ETM3 e ETM4 do Landsat. No caso do cálculo do índice NDII foram utilizadas a primeira banda do infravermelho médio (SWIR) SWIR1, no lugar da banda 5 do

Landsat e a banda VNIR3 no lugar da banda 4 do Landsat. Como no ASTER as bandas VNIR apresentam resolução espacial de 15m optou-se em transformá-las na resolução de 30m.

4.2.5 Transformação das Componentes Principais

Trata-se de uma transformação linear pela qual um novo sistema espectral ortogonal de coordenadas é definido de forma que a correlação entre bandas pode ser minimizada. Os eixos deste novo sistema correspondem aos *autovetores* da matriz de covariância ou correlação do conjunto de bandas da imagem. Trata-se de uma técnica aplicada para remover ou reduzir a redundância de informação espectral existente entre duas bandas (LILLESAND e KIEFER, 1994). A Transformação das Componentes Principais serve para realçar a imagem através da combinação de várias bandas, sendo que os novos eixos representam direções com variabilidade máxima dos dados (JOHNSON e WICHERN, 1982).

Os autovalores associados a cada autovetor da matriz de covariância expressam a porcentagem de informação original representada em cada componente. Os autovetores, por sua vez, indicam a ponderação que se deve aplicar a cada uma das bandas originais para se obter a nova componente, em outras palavras, os autovetores equivalem aos coeficientes de uma transformação linear. Ao estudar as concentrações de umidade de uma imagem de Madri, CHUVIECO (1990) aplicou a transformação das componentes principais à imagem do sensor TM e correlacionou o resultado com a concentração de umidade. A componente que gerou o melhor resultado tinha associação positiva com a banda 5 e negativa com as três bandas do visível, um resultado compatível com o comportamento da umidade nos solos. Este método é especialmente aplicado na análise multitemporal porque sua padronização pode minimizar os efeitos da atmosfera e do ângulo de incidência solar (CHUVIECO, *op.cit*).

No presente estudo, optou-se por utilizar as duas componentes principais derivadas apenas das bandas do infravermelho médio, ETM5 e ETM7, do Landsat. Os autovetores obtidos com esta transformação foram 1= 641.886 e 2=7.649. A matriz de


correlação indicou correlação de 0.9697 entre ETM5 e ETM7 e por fim os dois primeiros componentes foram formados de acordo com as equações (4.10) e (4.11).

$$PC1 = 0.860344 * ETM5 + 0.509713 * ETM7 \quad (4.10)$$

$$PC2 = -0.509713 * ETM5 + 0.860344 * ETM7 \quad (4.11)$$

A FIGURA 4.2 exemplifica os dois primeiros componentes da transformação dos componentes principais entre as bandas ETM5 e ETM7, para a estação de Acerra.

FIGURA 4.2 – COMPONENTES PRINCIPAIS ENTRE ETM5 E ETM7, ESTAÇÃO DE ACERRA. EM3D.



A) PC1

B) PC2

4.2.6 Transformação *Tasseled Cap*

Esta transformação foi originalmente aplicada a sensores MSS do Landsat para entender o fenômeno de crescimento de campos agrícolas (Huang et al., 2002). Foi desenvolvida por Kauth e Thomas citado por Crist e Ciccone (1984) e consiste, basicamente, em se obter novas bandas através de combinação linear das bandas originais. A diferença entre esta transformação e a das componentes principais é que os coeficientes da transformação *Tasseled Cap* são constantes aplicadas a qualquer imagem e não dependem da distribuição dos dados da imagem. Além disso, as novas componentes não são necessariamente ortogonais. Desta forma os dados sofrem a

mesma transformação no espaço espectral e a maioria das informações é disposta em relação a novos eixos que estão relacionados diretamente a características físicas da cena (LILLESAND e KIEFER, 1994) utilizando a expressão (4.12):

$$u_j = R'_i x_i + c \quad (4.12)$$

onde

u_j = vetor correspondente à imagem transformada

x_i = vetor de entrada

e

R'_i = vetor dos coeficientes de transformação

c = constante.

Como esta transformação foi proposta para o estudo de campos agrícolas, as componentes estão associadas a fenômenos visíveis em campos agrícolas. Dois eixos principais foram determinados, um deles associado ao BRILHO (*brightness*), que corresponde à soma ponderada de todas as bandas do sensor e é definido na direção da variação principal da reflectância do solo. O segundo eixo corresponde ao VERDE e é mais conhecido como *greenness*, é ortogonal ao primeiro eixo e corresponde ao contraste entre as bandas do infravermelho próximo e do visível. Este eixo é fortemente associado à presença de vegetação na cena (LILLESAND e KIEFER, 1994).

CRIST e CICONE (1984) desenvolveram um estudo utilizando esta transformação para o sensor TM do Landsat baseado no número digital (ND). Neste estudo os autores verificaram que para as seis bandas do TM novo eixo, além dos componentes BRILHO (*brightness*) e VERDE (*greenness*) já definidos no modelo original proposto para dados do sensor MSS, poderia ser proposto. Este novo eixo corresponderia à UMIDADE (*wetness*) e estaria relacionado ao conteúdo de umidade da vegetação e do solo, nitidamente vinculado à banda do infravermelho médio. A combinação destes três eixos permitiu distinguir três planos: o de vegetação, formado pelo eixo do brilho e do verde; o de solos, formado pelo brilho e umidade; e o de

transição formado pela umidade e verde. Posteriormente CRIST (1985) adaptou esta transformação utilizando os valores de reflectância ao invés dos números digitais.

Huang *et al.* (2002) fizeram uma adaptação da transformação *Tasseled Cap* para o Landsat 7 ETM. Os coeficientes de transformação obtidos em cada uma das bandas (BRILHO, VERDE e UMIDADE) são apresentados na TABELA 4.4.

TABELA 4.4 - COEFICIENTES TASSELED CAP PARA LANDSAT 7 ETM+

	ETM1	ETM2	ETM3	ETM4	ETM5	ETM7
BRILHO	0.3561	0.3972	0.3904	0.6966	0.2286	0.1596
VERDE	-0.3344	-0.3544	-0.4556	0.6966	-0.0242	-0.2630
UMIDADE	0.2626	0.2141	0.0926	0.0656	-0.7629	-0.5388

FONTE: HUANG *et al.* (2002)

Segundo CHUVIECO (1990), uma das vantagens desta transformação sobre a Análise de Componentes Principais diz respeito à sua interpretação física, pois as componentes deduzidas a partir da Transformação *Tasseled Cap* se baseiam nas características das bandas espectrais em consideração.


No entanto, as duas transformações guardam uma certa semelhança. Pode-se dizer que, por tratar-se de uma combinação linear de todas as bandas, a banda BRILHO se assemelha em muito à imagem da primeira componente principal. Ao mesmo tempo, por utilizar bandas do visível e infravermelho próximo, a banda VERDE assemelha-se a o índice NDVI.

Um aumento no conteúdo de umidade tende a ser associado a valores mais baixos da banda BRILHO e na Banda UMIDADE estes valores se aproximam de zero (CRIST e CICONE, 1984), já que a banda umidade corresponde ao contraste das bandas do infravermelho médio e a água apresenta alta absorção no infravermelho, fazendo com que sua resposta seja bem baixa neste comprimento de onda. Assim, espera-se que áreas onde haja muita umidade apresentem baixos valores da banda umidade da transformação *Tasseled Cap*.

A FIGURA 4.3 exemplifica a banda umidade da transformação *Tasseled Cap* na estação pluviométrica de Acerra, uma das vinte estações localizadas na área de

estudo e onde foram coletados os valores espectrais de pontos para se realizar a correlação com o acumulado de chuva.

FIGURA 4.3 – TRANSFORMAÇÃO TASSELED CAP, BANDA UMIDADE, ESTAÇÃO DE ACERRA EM 3D.



Neste estudo optou-se em se adaptar a transformação *Tasseled Cap*, para as imagens ASTER. Neste caso utilizou-se os coeficientes correspondentes à banda umidade, que será denominada por TU, calculados para a imagens Landsat (TABELA 4.4, última linha) e substituindo as bandas do Landsat ETM pelas correspondentes ASTER. As bandas do visível do ASTER (VNIR1, VNIR2) foram usadas em lugar das bandas 2 e 3 do Landsat. Não existe uma banda equivalente à banda 1 do TM para o ASTER. A banda VNIR3, do infravermelho próximo, foi usada para substituir a banda 4 do Landsat, embora a faixa espectral seja levemente diferente. As bandas SWIR correspondem às bandas do infravermelho médio. A primeira banda desta faixa, a banda 4 do ASTER, foi usada em lugar da banda 5 do TM, embora a faixa espectral seja um tanto diferente, em torno de $0,5\mu\text{m}$. Como o ASTER oferece um maior número de bandas na faixa equivalente à banda 7 do Landsat, os dados das bandas 5, 6 e 7 do ASTER foram combinadas para substituir a banda 7 do TM.

Para isto, a transformação das componentes principais foi aplicada a estas três bandas e a primeira componente PC (SW) foi usada para representar a banda 7 do

TM. É importante salientar que a transformação tasseled cap, banda umidade, para imagens ASTER foi feita com todas as bandas na mesma resolução espacial, 30 metros. Desta forma a banda umidade da transformação *Tasseled Cap* (TU) para a imagem ASTER foi calculada como mostra a equação 4.13.

$$TU = VNIR1 * 0.2141 + VNIR2 * 0.0926 + VNIR3 * 0.0656 + SWIR1 * -0.7629 + PC(SWIR2, SWIR3 \text{ e } SWIR4) * -0.5388 \quad (4.13)$$

4.3 SEGUNDA FASE: OBTENÇÃO DOS DADOS DE VERDADE DE CAMPO

4.3.1 Seleção do Acumulado de Chuvas

Para se descrever a umidade do solo utilizou-se um índice de acumulado de chuvas obtido em vinte estações pluviométricas: Acerra, Agropoli, Altavilla Silentina, Bacoli, Baronissi, Battipaglia, Buccino, Buonabitacolo, Casalvelino, Castel S.Lorenzo, Giugliano, Giugliano L, Gromola, Policastro Bussentino, S.Marzano nos municípios de Nápoles e Salerno, região de Campania. FIGURA 4.4.

FIGURA 4.4 – DISTRIBUIÇÃO DAS ESTAÇÕES PLUVIOMÉTRICAS NA ÁREA DE ESTUDO



FONTE: adaptado de< <http://www.regione.campania.it/agricoltura/meteo/reterete.htm>>

O índice de acumulado de chuva dos últimos três dias é um índice pluviométrico utilizado pela Secretaria do Meio Ambiente do Estado de São Paulo e pela defesa Civil do Estado de São Paulo para a determinação dos índices de "atenção", "alerta" e "alerta máximo" a escorregamentos na região litorânea. Segundo CEDEC (1996), a análise de alguns episódios de chuvas que provocaram escorregamentos no litoral de São Paulo permitiu estabelecer que valores de chuvas acumulados em 3 dias. Os dados indicam que acima de 100mm para a Baixada Litorânea e 120 mm para o litoral norte de São Paulo há alta possibilidade de ocorrência de escorregamento.

Como a área em estudo apresenta características climáticas, geomorfológicas e geológicas muito distintas da região litorânea do estado de São Paulo seria um erro muito grosseiro utilizar o mesmo valor de acumulado de chuva nesta região. Desta forma procurou-se estudar a variação dos dados pluviométricos através do acúmulo de chuva (mm) em 2, 4, 6 e 8 dias em relação à data de aquisição das imagens.

Calculou-se o acúmulo de chuva dos dias anteriores à aquisição da imagem mais metade do acúmulo de chuva do dia de aquisição da imagem. Por exemplo, para o dia 22 de novembro de 2002 o acumulado de 2 dias corresponde a pluviosidade do dia 20, 21 e metade da pluviosidade do dia 22. Procurou-se obter, quando possível, imagens que representassem períodos mais chuvosos e mais secos para tentar caracterizar espectralmente esta variação.

O Anexo I traz a informação da localização das estações pluviométricas e dados dos acumulados de chuvas em cada estação e para cada data de aquisição das imagens dos diferentes sensores. No caso das imagens ASTER nem todas as 20 estações são cobertas por todas as imagens, porém isto não interferiu no estudo uma vez que se dispunha de um número elevado de imagens deste sensor, adquiridas em diferentes períodos.



Após o estudo da correlação individual de algumas bandas e índices optou-se em utilizar-se o acumulado de chuva de quatro dias (Ac4) para a realização de todas as análises.

4.3.2 Critérios para escolha dos Pontos e Forma de Medição dos Dados

Uma vez tendo os acumulados de chuvas de 2, 4, 6 e 8 dias para cada imagem/sensor e em cada estação pluviométrica selecionou-se pontos de medida dos dados espectrais em cada tipo de solo para cada estação pluviométrica e para cada imagem. Na escolha dos pontos, procurou-se escolher pontos que representasse a confluência de vertentes, onde o acúmulo de água é maior (FIGURA 4.5). Estes pontos foram escolhidos com o auxílio do modelo digital do terreno (DEM). O DEM foi utilizado para se criar uma imagem em 3D onde o ponto para a leitura dos índices e das bandas pudesse ser escolhido com exatidão.

FIGURA 4.5 – POSIÇÃO NA VERTENTE DO PONTO DE MEDIÇÃO DOS DADOS ESPECTRAIS

Janela de Leitura



Este processo deu-se da seguinte forma:

1. Utilizou-se o DEM relativo, obtido pela imagem ASTER com grade de 30 metros;
2. Criou-se uma imagem 3D, FIGURA 4.5, utilizando a composição colorida (5,4,3 ou 3,2,1 como melhor se visualizavam as vertentes).
3. Foram escolhidos ao menos três pontos por cada tipo de solo por cada estação meteorológica.

Um programa desenvolvido para a leitura dos pontos foi criado em Matlab. Para medir o valor spectral do ponto escolhido fez-se a leitura dos valores de uma

janela 3x3 e calculou-se a média das leituras (FIGURA 4.5). Este processo só foi aplicado para as imagens Landsat e ASTER, de resolução média, para se evitar erros na leitura do ponto causados pelo erro mínimo de registro das imagens. Para as imagens MODIS por tratar-se de baixa resolução espacial o critério da janela 3x3 não foi utilizado e a leitura foi feita diretamente sobre o ponto.

4.3.3 Critérios para escolha dos Grupos de Solos

Devido à variação em termos de composição, textura e estrutura dos solos optou-se em realizar as análises segundo três principais eixos de estudo: o primeiro foi o estudo espectral de cada sensor (Landsat, ASTER e MODIS) de acordo com cada tipo de solo, posteriormente às diversas variedades de solos foram agrupadas em dois principais grupos e por último foi feito um estudo onde todos os solos foram avaliados conjuntamente.

Como mencionado anteriormente a área de estudo corresponde a municípios da região de Campania, sul da Itália, caracterizada por uma vasta variedade de solos.

O estudo espectral de cada sensor (Landsat, ASTER e MODIS) de acordo com cada tipo de solo visou caracterizar o comportamento espectral individual dos principais solos da região, para isso foram escolhidos solos com características geotécnicas muito distintas: Solos da **Categoria B** e Solos das **Categorias H e I** (DI GENNARO, 2002).

O estudo realizado por DI GENNARO (*op.cit*) agrupa os solos de acordo com uma abordagem analítica do tipo fisiográfico-integrado que se baseia no reconhecimento do ambiente geográfico. Desta forma entram na classificação do solo além das características texturais, estruturais as características geomorfológicas do terreno como declividade da vertente.

Neste estudo DI GENNARO (*op.cit*) utiliza como critérios de classificação:

1. Disponibilidade de Oxigênio: que caracteriza a disponibilidade de oxigênio para a atividade biológica do solo que é avaliada com base na presença de água, capilaridade, etc.

2. Interferência Climática: referencia para a escolha da cultura agrícola a ser praticada na região. As faixas de classificação relacionam-se à potencialidade produtiva de pratica agrícola.
3. Horizonte: estrato paralelo à superfície com características do processo de formação do solo e subdividido em: horizonte superficial, normalmente cultivado e com profundidades entre 5 e 30cm; horizonte profundo, compreendido entre o horizonte superficial e o substrato rochoso e substrato, pouco afetado pelo processo pedogenético, porém não se trata da rocha propriamente dita.
4. Declividade da Vertente: refere-se a declividade da vertente. É subdividida em 7 classes que variam de plana, com declividade inferior a 0,2% a muito íngreme, que é superior a 45%.
5. Pedregosidade Superficial: é a proporção relativa de seixos com diâmetro superior a 25cm sobre o solo. Possui 5 classes que vão desde pedregosidade ausente, com até 0,01% de clastos até extremamente pedregoso, com mais de 90% de clastos.
6. Perfil: trata-se da seqüência de formação relativa a uma secção vertical do solo.
7. Profundidade do Solo: é entendida como a profundidade que ocorre entre o solo e um estrato coerente e contínuo localizado abaixo.
8. Rochosidade: presença de estratos aflorantes de rocha. É classificada em seis grupos que vão desde nenhuma rochosidade, onde a presença de rocha aflorante é inferior a 2%, até rocha aflorante, quando esta porcentagem é superior a 90%.
9. Textura: é a proporção relativa, em peso, das principais frações granulométricas do solo inferiores a 2mm de diâmetro. É classificada em 6 grupos que variam desde grossa, onde há o predomínio da textura areia (até 0,05mm) até fina, onde predomina a argila (inferior a 0,002mm de diâmetro).

Para o estudo da umidade do solo será de grande importância características como a disponibilidade de oxigênio conjuntamente com a profundidade do solo, a declividade, textura e perfil. É evidente que tais características encontram-se intrinsecamente relacionadas, pois com uma alta declividade esperam-se perfis rasos de solo e pouco acúmulo de água.

A área em estudo apresenta as seguintes variedades de solo:

Tipo A – **Solos de Alta Montanha.** Os solos desta unidade que ocorrem na área de estudo caracterizam-se por serem solos calcáreos com cobertura piroclástica. São moderadamente profundos a profundos (50 a 100 cm) desenvolvidos sobre depósitos de cinzas e recobertos por rocha calcária. Em geral a textura é média e com boa disponibilidade de oxigênio, o que indica que a água é removida do solo rapidamente. Ocorre em vertentes íngremes ou muito íngremes.

Tipo B – **Solos de Montanha Calcárea.** Os solos que ocorrem nesta unidade ocorrem em área com relevo íngreme ou muito íngreme de composição calcárea com cobertura piroclástica e sobre depósito de caída de cinzas. A textura é média ou moderadamente grossa e apresentam boa disponibilidade de oxigênio.

Tipo C – **Solos de Montanha Marnoso-Arenácea e Marnoso-Calcárea.** Os solos pertencentes a esta classe que ocorrem na área de estudo apresentam alternância de marga (calcário_argiloso)-arenáceo e conglomerados. A textura é moderadamente fina a fina e a disponibilidade de oxigênio é boa a moderada sendo que em alguns períodos do ano a água é removida do solo lentamente. Ocorre na estação pluviométrica de Casalvelino.

Tipo D – **Solos de Colina Interna.** Os solos desta unidade que ocorrem na área de estudo caracterizam-se por serem argilosos com cobertura piroclástica e solos marnosos-arenáceos. Ocorrem em áreas íngremes a moderadamente inclinadas. São profundos (entre 100 a 150 cm de espessura), com textura

moderadamente fina a fina e com disponibilidade de oxigênio boa a moderada, apresentando certa dificuldade da remoção da água.

Tipo E – **Solos de Colina Costeira.** Os solos desta unidade que ocorrem na área de estudo caracterizam-se por apresentarem composição predominantemente marnoso-arenácea - argilosa, ocorrerem em vertentes íngremes a moderadamente íngremes, apresentarem perfil profundo à moderadamente profundo e apresentarem alternância de textura, média em superfície é fina ou moderadamente fina em profundidade.

Tipo F – **Solos do Complexo Vulcânico.** Trata-se de solos que se desenvolveram sobre depósitos de caída de cinzas e pomes em vertentes levemente inclinadas a moderadamente íngremes, com textura moderadamente grossa e com perfil muito profundo (superior a 150 cm). Apresentam boa disponibilidade de oxigênio.

Tipo G – **Solos de Planícies.** Tratam-se de solos de relevos calcáreos e vulcânicos que ocorrem em regiões de planície onde apresentam grande profundidade (superior a 150 cm). Desenvolveram-se sobre depósitos de caída de cinzas. Textura moderadamente grossa e com boa disposição de oxigênio. Localmente apresentam estratos compactos de cinza vulcânica, presentes entre 50 a 70 cm de profundidade.

Tipo H – **Solos de Terraço Aluvional.** Os solos desta unidade que ocorrem na área de estudo caracterizam-se por serem profundos ou muito profundos (acima de 100cm). Desenvolverem-se sobre depósitos aluvionares antigos. Textura fina a moderadamente fina e com disposição de oxigênio moderada ou imperfeita.

Tipo I – **Solos de Planície Aluvionar.** Trata-se de solos muito profundos que ocorrem em áreas planas sobre depósitos aluvionares, material tufáceo ou ignimbrítico. Textura média com disposição de oxigênio variável.

Inicialmente foram escolhidos solos que pudessem caracterizar comportamentos distintos no que se relaciona aos itens que mais possam interferir na umidade do solo como disponibilidade de oxigênio, textura, profundidade e composição.

Para a caracterização individual dos solos foram escolhidos os solos do **Tipo B** e solos dos **Tipos H e I**. Os solos do Tipo H e I foram unidos por apresentarem características geotécnicas muito próximas (solos muito profundos, ocorrendo em áreas mais planas com disponibilidade de oxigênio irregular e textura média a fina) e por representarem juntos um número maior de amostragem, permitindo desta forma uma maior significância estatística.

A TABELA 4.5 indica o número de amostras utilizadas por solo e por sensor para este estudo. Em M está o número de amostras utilizadas na modelagem e em V o número de amostras utilizadas para a verificação.

TABELA 4.5 – NÚMERO DE AMOSTRAS UTILIZADAS POR SENSOR PARA OS SOLOS B E H&I.

	Landsat		ASTER		MODIS	
	M	V	M	V	M	V
Solo B	8	0	9	0	13	0
Solo H & I	10	3	10	3	13	0

Uma segunda abordagem agrupou os solos com características geotécnicas mais próximas. Foram formados dois grandes grupos: B, F & G e D, E, H&I. Entre as características geotécnicas comuns ao grupo B, F & G destaca-se o fato de terem se desenvolvido sobre depósitos de caída de cinzas, apresentarem textura moderadamente grossa e apresentarem boa disponibilidade de oxigênio. Já o grupo composto pelos solos D, E, H &I tendem a serem argilosos, com textura moderadamente fina a fina e com disponibilidade de oxigênio moderada, apresentando certa dificuldade da remoção da água. A TABELA 4.6 indica o número de amostras utilizadas por grupo de solo e por sensor para este estudo.

TABELA 4.6 – NÚMERO DE AMOSTRAS UTILIZADAS POR SENSOR PARA OS GRUPOS DE SOLOS B, F & G D, E, H&I.

	Landsat		ASTER		MODIS	
	M	V	M	V	M	V
Solos B, F & G	12	5	13	4	12	4
Solos D, E, H & I	15	5	14	6	14	6

A última abordagem agrupa todos os tipos de solos. Isso foi feito para averiguar-se se mesmo apresentando grande variedade textural, composicional poder-se-ia criar um modelo que fosse sensível à variação da umidade do solo. A TABELA 4.7 indica o número de amostras utilizadas por sensor para este estudo.

TABELA 4.7 – NÚMERO DE AMOSTRAS UTILIZADAS POR SENSOR PARA TODOS OS SOLOS.

	Landsat		ASTER		MODIS	
	M	V	M	V	M	V
Todos os solos	27	10	19	08	22	11

As TABELAS 4.6 e 4.7 não condizem em número porque em alguns casos a ocorrência de solos isolados como o Solo A ou C foi acrescida também na tabela 4.7 e nos casos de alguns dados não foram reutilizados na última análise por apresentarem informação redundante.

4.4 TERCEIRA FASE: CORRELAÇÃO ENTRE ACUMULADO DE CHUVAS X DADOS ESPECTRAIS: CRITÉRIOS PARA ESCOLHA DAS ANÁLISES

A escolha do modelo mais adequado é uma tarefa bastante difícil. Em primeiro lugar deve-se levar em conta a relação entre as diversas variáveis independentes (no caso as bandas e índices de cada sensor) e a variável dependente (o acumulado de chuva).

Tratando-se de uma análise multivariada procurou-se primeiro analisar a correlação individual de cada banda/índice espectral com os índices de 2, 4, 6 e 8 dias de acúmulo de chuva e analisou-se sua distribuição. A partir deste estudo optou-se pela análise multivariada, procurando um modelo linear ou não linear.

A Análise Discriminante, a Análise de Correlação Múltipla e a GMDH-rede

neural polinomial (PNN) foram escolhidas para obter-se uma equação ótima que contivesse as bandas/índices espectrais mais sensíveis na determinação da umidade do solo para cada sensor.

Através de uma análise de correlação simples entre cada variável independente e as variáveis dependentes (acumulados de chuva) observou-se que o melhor acumulado de chuva era o de 4 dias. Assim este foi utilizado como variável dependente em todas as análises.

Como variáveis independentes foram utilizados:

Para a imagem Landsat: o NDII, NDVI, Tasseled Cap banda umidade, transformação de componentes principais (das bandas TM5 e ETM7) 1º e 2º componentes e banda termal.

Para as imagens ASTER foram utilizadas as bandas do infravermelho (SWIR), os índices NDII, NDVI, Tasseled Cap banda umidade e a temperatura superficial.

E para as imagens MODIS foram utilizadas as bandas do visível e do infravermelho bem como a temperatura superficial noturna.

4.4.1 Análise Regressão Múltipla

A análise de regressão é uma técnica estatística muito utilizada. A Regressão Múltipla permite criar modelos para cada uma das variáveis independentes (preditoras) como uma função linear da variável dependente ou das variáveis dependentes (respostas). A análise de regressão múltipla é uma modelagem linear. Na verdade, segundo JOHNSON e WICHERN (1988), o termo linear se refere ao fato de que a média é uma função linear dos parâmetros não conhecidos (β , β_1 ,... β_r) mas as variáveis preditoras (independentes) podem entrar ou não como um termo de 1º ordem. O modelo clássico de regressão é dado pela equação (4.14).

$$Y = \beta + \beta_1 Z_1 + \dots + \beta_r Z_r + \varepsilon \quad (4.14)$$

onde:

Y = variável dependente ou resposta e tem dimensão n = número de observações,

$Z_1.. Z_r$ = variáveis independentes

$\beta, \beta_1.. \beta_r$ = parâmetros de regressão, em um total de p = número de parâmetros do modelo

ε = erro

No caso de um número n de variáveis independentes tem-se

$$\begin{aligned} Y_1 &= \beta_0 + \beta_1 Z_{11} + ... + \beta_r Z_{1r} + \varepsilon_1 \\ Y_2 &= \beta_0 + \beta_1 Z_{21} + ... + \beta_r Z_{2r} + \varepsilon_2 \\ &... \\ Y_n &= \beta_0 + \beta_1 Z_{n1} + ... + \beta_r Z_{nr} + \varepsilon_n \end{aligned} \quad (4.15)$$

Na Regressão Múltipla cada variável independente é isolada e mantida constante enquanto as demais variáveis independentes variam sistematicamente, sendo observados os seus efeitos sobre a variável dependente. A variável independente a ser mantida é a que tem maior influência na variabilidade da variável dependente. Na equação anterior, a variável que mais reduz a variabilidade do erro é mantida na equação múltipla.

Um parâmetro a ser avaliado e o coeficiente de correlação múltipla ao quadrado (R^2) ou como também é conhecido coeficiente de determinação, ou ainda R -quadrático. Calculado a partir da equação (4.16).

$$R^2 = \Sigma (\hat{y}_i - \mu)^2 / \Sigma (y_i - \mu)^2 \quad (4.16)$$

O R^2 nada mais é que a relação entre a soma dos quadrados da regressão e a soma dos quadrados total, desta forma deve variar entre 0 e 1 sendo que valores próximos a 1 indicam um bom ajuste do modelo. Há também o R^2 ajustado que é utilizado para comparar modelos com um número diferente de variáveis independentes, equação (4.17).

$$R^2 \text{ ajustado} = 1 - (1 - R^2)(n-1)/(n-p-1) \quad (4.17)$$

Quando o estudo é feito “passo a passo” ou *Stepwise regression*, as variáveis independentes são avaliadas individualmente quanto à sua influência sobre a variabilidade da variável dependente através dos seus coeficientes e do erro. A variável que reduz a variabilidade do erro é mantida no modelo. Isso segue até que todas as variáveis independentes sejam analisadas.

O problema maior no uso de modelos de regressão é o fato de não se conhecer o grau do polinômio que melhor descreve a relação entre as variáveis. Mais ainda, o modelo pode não ser necessariamente linear, quando uma transformação, por exemplo, logarítmica, deve ser aplicada. Por este motivo, nesta abordagem deve se proceder de maneira progressiva, começando pelo uso de modelos mais simples e aumentando o grau do polinômio nas seguintes etapas. Outro problema é a seleção das variáveis mais significativas.

Neste estudo a combinação da regressão múltipla conjuntamente com o algoritmo GMDH mostrou-se um método eficiente de seleção das variáveis independentes e na modelagem de predição do acumulado de chuva. Como será visto mais adiante, neste estudo será utilizado o algoritmo GMDH para ajudar a encontrar com as variáveis independentes já não mais em 1º ordem, mas em 2º ou 3º ordem de acordo com o resultado obtido com o algoritmo GMDH.

4.4.2 GMDH - Group Method of Data Handling

O GMDH é um algoritmo de busca de uma função que descreva a relação entre as variáveis baseado no conceito evolutivo de seleção natural. Na primeira etapa, o algoritmo combina as variáveis de entrada usando polinômios simples, binômios de segundo grau, e procura os binômios que melhor descrevem a variável dependente. A seguir, em um processo iterativo, o resultado dos melhores binômios é usado para gerar um novo conjunto de variáveis, as quais novamente são combinadas em pares. Assim, dentro do processo iterativo, o grau do polinômio é aumentado e as variáveis

mais significativas para o modelo são selecionadas e usadas para gerar um novo conjunto de variáveis, teoricamente mais significativas, enquanto as menos significativas são descartadas. O processo se inicia, por exemplo, com as variáveis de entrada do tipo x_i, x_j, x_k . A partir da combinações destas variáveis é gerado um novo conjunto de variáveis do tipo w_i, w_j, w_k que são combinações do nível anterior.

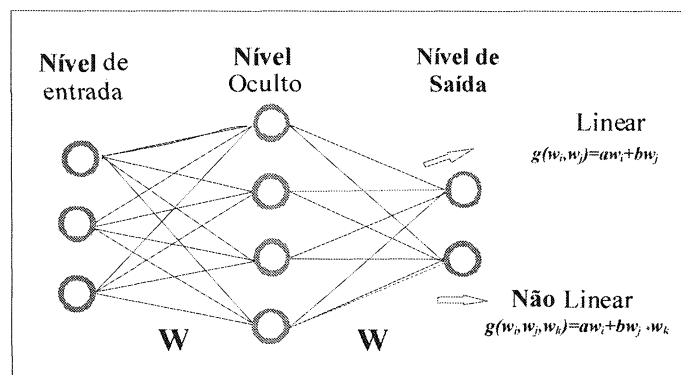
$$w_{01}=x_1; w_{02}=x_2; w_{03}=x_3; \dots w_{0n}=x_n;$$

$$w_{1t} = f(w_{0i}, x_{0j})$$

$$w_{2t} = f(w_{1i}, x_{1j})$$

Desta forma são gerados diferentes níveis (*layers*) onde o primeiro nível gera um modelo do tipo $y = g(x_i, x_j, x_k)$ e o próximo nível gera $y=g(w_i, w_j, w_k)$. Para cada nova variável gerada é verificado o grau de correlação com a variável de saída “y”. Analisando os valores da correlação ara cada nova variável, as melhores combinações são selecionadas descartando-se as piores. As melhores combinações são então, em uma nova fase do processo iterativo, combinadas de forma a se obter um novo conjunto de variáveis e o processo é então repetido (FIGURA 4.6).

FIGURA 4.6 - ESQUEMA GERAL DA ESTRUTURA DO ALGORITMO GMDH.



FONTE: [ftp://pnn.pnnsoft.com/articles.html](http://pnn.pnnsoft.com/articles.html)

Como descrito no parágrafo anterior o algoritmo inicia-se efetuando combinações simples entre duas variáveis de entrada, utilizando um polinômio de segundo grau, por exemplo. A medida em que um novo nível é criado identifica-se o

melhor polinômio de predição da variável e calcula-se seu erro. O número de camadas aumenta até que já não ocorra uma melhora na iteração ou até que se limite o grau do polinômio. O elemento que apresenta o menor erro é escolhido e suas variáveis são substituídas.

A equação de predição assume o seguinte formato:

$$y = a + \sum b_i x_i + \sum c_{ij} x_i x_j + \sum d_{ijk} x_i x_j x_k + \text{etc.} \quad (4.18)$$

onde:

y = variável dependente;

a, b, c, d = parâmetros do polinômio;

x_i, x_j, x_k = variáveis independentes.

Neste estudo, para a predição da umidade do solo através do acumulado de chuva, todas as bandas e índices espectrais foram utilizados como variáveis de entrada no primeiro nível. Com estas variáveis, o algoritmo GMH gerou polinômios em função do número de iterações estipulado.

No intuito de conduzir a seleção de variáveis, a metodologia adotada utilizou o algoritmo GMDH de duas formas: (1) com todas as variáveis independentes para cada sensor, limitando-se em um polinômio de 3º grau (2) somente com as variáveis que produziram os melhores resultados nos modelos de regressão múltipla. Concomitantemente uma segunda regressão múltipla foi aplicada utilizando a relação não-linear obtida no GMDH. Assim obtiveram-se duas análises do tipo regressão múltipla e duas análises do tipo GMDH. Desta forma conseguiu-se selecionar uma combinação de variáveis independentes bastante significativa para a predição do acumulado de chuvas.

O polinômio foi limitado a um polinômio de 3º grau por dois motivos: como a intenção é gerar uma equação capaz de modelar a umidade do solo, para que este modelo tenha uma aplicabilidade grande é interessante que as equações sejam o mais simplificadas possível. O segundo motivo é o conhecido por *overfitting*. Estudos

anteriores (KISHI, 2001) reconhecem que quando o polinômio é de grau muito elevado o ajuste da função aproxima-se bem dos valores de entrada, porém gera erros na predição. Modelos com mais de 7 iterações se mostram instáveis.

4.4.3 Análise Discriminante

A Análise Discriminante é uma combinação linear de duas ou mais variáveis independentes que irá discriminar grupos definidos *a priori*. A variável dependente é do tipo categoria e as variáveis independentes são métricas. Esta análise baseia-se na maximização da variância entre grupos. A função geral discriminante (4.19) é dada por:

$$Z = W_1X_1 + W_2X_2 + \dots + W_nX_n \quad (4.19)$$

onde:

Z = escore discriminante

W_i = pesos discriminantes

X_i = variáveis independentes

A média dos escores discriminantes é conhecida como centróide. Os grupos terão centróides distintos se forem bem diferentes.

A Análise Discriminante é semelhante à Regressão Múltipla, com a diferença de que a variável dependente é métrica nesta última técnica e no caso da primeira ela é categórica, contudo na Análise Discriminante a variável dependente pode ser criada como categórica, mesmo sendo métrica (JOHNSON, 1998).

O procedimento geral consiste em identificar as características onde existem as maiores diferenças entre os grupos e depois atribuir um coeficiente ponderal discriminante para cada variável que reflita estas diferenças. Posteriormente cada observação é alocada a um grupo, usando os pesos e os escores de cada observação.

É necessário que exista uma regra para prever em que grupo uma nova medida (x) será alocada. Para isso é possível abordar segundo quatro tipos distintos de

regra: (1) de acordo com a regra do vizinho, (2) de acordo com uma função linear discriminante, (3) de acordo com a distância de Mahalanobis e (4) de acordo com a regra da probabilidade posterior (JOHNSON, *op.cit*).

Recomenda-se que o tamanho da amostra seja no mínimo de 20 observações por grupo, por este motivo optou-se neste estudo em desenvolver a análise discriminante para todos os tipos de solos juntos, de forma a poder dispor de mais dados e de averiguar-se a capacidade de classificação em comportamento espectral heterogêneo. É importante, porém que quando a análise for realizada com um grupo menor de amostras, este grupo exceda o número de variáveis preditoras, o que ocorreu, pois para o Landsat foram utilizadas 6 variáveis independentes: NDVI, NDII, Tasseled Cap - umidade, PC1, PC2 e banda Termal; para ASTER foram utilizadas as 6 bandas do infravermelho (SWIR) e a temperatura superficial, ou seja, 7 variáveis independentes e no caso do MODIS foram utilizadas 7 bandas (visível e infravermelho próximo e médio) além da temperatura superficial noturna.

É importante também que os grupos não tenham tamanhos muito diferentes, porque isto afeta a análise; grupos maiores têm maior chance de classificação.

Em geral obtém-se a função discriminante em um grupo de observações e testa-se em outro grupo para sua validação. Um grupo é utilizado para a modelagem e outro para verificação. No caso de amostras pequenas pode-se testar a função no próprio grupo, apesar da tendenciosidade dos resultados.

Na Análise Discriminante é importante analisar: as matrizes de classificação, o escore de corte, modelos aleatórios, eficiência da classificação relativa ao acaso.

Matriz de classificação é uma matriz que revela a capacidade de predição da função discriminante. Os números da diagonal da matriz representam as classificações corretas e os fora da diagonal as classificações erradas.

Escore de corte (Z) é o utilizado para determinar em que grupo a amostra será classificada. Se os grupos são de mesmo tamanho, o Z crítico é a média aritmética simples. Senão, deve ser calculada a média aritmética ponderada com os tamanhos das amostras.

A matriz de classificação é construída calculando-se o Z crítico de corte e comparando a ele o Z de cada observação, verificando se a classificação está correta.

Os coeficientes discriminantes revelam se uma variável é muito discriminante ou não. Variáveis com altos coeficientes são mais discriminantes do que as com baixos coeficientes. Os coeficientes discriminantes indicam a contribuição que as variáveis independentes tem na função.

Neste estudo, embora a variável dependente (acumulado de chuva) fossem métrica, a análise discriminante foi aplicada. Porque tendo um número pequeno de observações, com valores distintos de acumulados de chuva, pode-se dizer que se trata de “grupos” diferentes e a partir daí, uma função que consiga discriminar acumulados de chuva muito distintos será uma boa função para detecção da umidade.

Optou-se então por categorizar o acumulado de chuva em valores que variavam a cada 10mm. Desta forma, foram criadas “categorias” de 0mm, 10mm, 20mm até 60mm, que foi o valor máximo obtido com o acumulado de chuva.

4.5 QUARTA FASE: VERIFICAÇÃO DOS RESULTADOS

4.5.1 Teste Kolmogorov-Smirnov.

Para a verificação dos resultados obtidos com as análises multivariáveis utilizou-se o teste de Kolmogorov-Smirnov. O Teste de Kolmogorov-Smirnov (teste de K-S) é aplicado, também no caso de amostras pequenas, para o estudo da igualdade estatística de duas populações. O teste de K-S procura diferenças entre a função de distribuição das duas populações baseada em dois grupos de amostras independentes. Sua vantagem é que não há comprometimento do teste se a distribuição dos dados não for normal, pois se trata de um teste não-paramétrico e de distribuição livre.

O Teste K-S avalia se duas populações tem distribuição semelhante, ou melhor, se foram extraídas de uma mesma população. É um teste muito sensível e detecta diferenças em relação à tendência central, dispersão e simetria. O princípio

básico é comparar as frequências acumuladas das duas amostras.

Ele é calculado da seguinte maneira:

1. Ordena-se duas seqüências de amostras.
2. Constroem-se as distribuições de frequências acumuladas nos intervalos de classe de cada amostra.
3. Calcula-se as diferenças entre as frequências acumuladas de cada amostra em cada um dos intervalos de classe (D). No caso deste estudo considera-se as diferenças entre a primeira população, que corresponde aos dados de acumulados de chuva observados e a segunda população que corresponde aos dados de acumulados de chuva obtidos com os diferentes modelos gerados pelas análises multivariadas.
4. Escolhe-se a maior diferença [D_{\max}] que será comparada com $D_{\text{crítico}}$.
Se $D_{\max} \geq D_{\text{crítico}}$ rejeita-se a hipótese de igualdade das amostras.

D_{\max} , ou D como é utilizado aqui, é a diferença absoluta máxima entre as duas funções (observada e obtida), desta forma, mesmo que as médias das populações se aproximem, mas se D for grande o teste aponta falta de similaridade entre as populações.

O valor de $D_{\text{crítico}}$ é o valor acima do qual a hipótese de igualdade das amostras é negada. Ele é calculado a partir do grau de significância que quer se dar para o teste e é dependente do número de amostras utilizados (n). Neste estudo utiliza-se para o cálculo do $D_{\text{crítico}}$ o valor de significância de 0.10. A TABELA 4.8 traz como pode ser calculado o $D_{\text{crítico}}$.

TABELA 4.8 – CÁLCULO DE $D_{\text{CRÍTICO}}$ DE ACORDO COM O NÍVEL DE SIGNIFICÂNCIA ESTATÍSTICA


Nível de Significância	$D_{\text{crítico}}$
$\alpha = 0.10$	$1.22 [(n1 + n2)/(n1.n2)]^{1/2}$
$\alpha = 0.05$	$1.36 [(n1 + n2)/(n1.n2)]^{1/2}$
$\alpha = 0.025$	$1.48 [(n1 + n2)/(n1.n2)]^{1/2}$
$\alpha = 0.01$	$1.63 [(n1 + n2)/(n1.n2)]^{1/2}$

Para entender melhor o cálculo de D pode-se observar a FIGURA 4.7. Ela traz a comparação entre a fração cumulativa entre os dados observados de acumulado de chuva para o solo B, imagem Landsat, e os dados obtidos com a primeira regressão múltipla realizada. O valor D_{\max} corresponde ao maior desvio vertical entre as duas curvas, que no caso corresponde a 0.25, que ocorre para os valores de acumulado de chuva entorno de 3mm onde nos dados observados há uma fração acumulada de 0.375 (ou seja, 37,5% dos valores observados) e para os dados gerados pelo modelo esta fração é 0.12 (ou seja, 12% dos valores gerados).

No presente trabalho o teste de Kolmogorov-Smirnov foi aplicado em todas as análises feitas utilizando individualmente os solos, em grupo ou todos os solos juntos, para cada sensor.

Comparativamente realizou-se o teste de correlação entre os dados observados e os dados obtidos com as modelagens. A combinação entre o resultado do teste K-S e da correlação serviu para apontar qual a melhor modelagem para cada sensor e em que situação.

FIGURA 4.7 – FRAÇÃO CUMULATIVA , TESTE K-S



5 MODELOS DE REGRESSÃO MÚLTIPLA

Neste estudo o método de aplicação da análise multivariada deu-se em três fases: inicialmente, aplicou-se a regressão múltipla utilizando como variáveis independentes aquelas indicadas pelo modelo, ou seja, aquelas que juntas apresentaram os melhores valores de R-quadrático e R-quadrático ajustado. Em uma segunda fase aplicou-se o algoritmo GMDH utilizando todas as variáveis como variáveis independentes e deixou-se que o algoritmo, através de suas iterações, selecionasse as variáveis independentes que iriam compor o modelo. A última fase foi aplicar novamente a regressão múltipla só que desta vez utilizando como variáveis independentes aquelas indicadas pelo algoritmo GMDH. Neste Capítulo são apresentados os resultados obtidos com a primeira regressão múltipla.

Esta metodologia foi aplicada para os três sensores (Landsat, ASTER e MODIS) e a todos os tipos de solos: nos solos individuais do tipo B e dos tipos H & I, posteriormente em dois grupos distintos de solos (B, F & G) e (D, E, H & I) e finalmente as análises foram realizadas utilizando-se dados de todos os tipos de solos simultaneamente. A variável dependente utilizada foi sempre o acumulado de chuva de quatro dias (Ac4).

Para a imagem Landsat, adquirida em 28 de novembro de 2002, o acumulado de chuva de quatro dias correspondeu ao acúmulo de chuva, em milímetros, dos dias 24, 25, 26, 27 e $\frac{1}{2}$ do dia 28 de novembro de 2002.

Para as imagens ASTER, como se dispunha de seis imagens adquiridas em 26 de setembro de 2000, 25 de junho de 2001, 20 de julho de 2001, 28 de janeiro de 2002, 20 de maio de 2002 e 17 de agosto de 2002, foram utilizados os acúmulos de chuva respectivamente dos períodos de 22 a $\frac{1}{2}$ do dia 26 de setembro de 2000, 21 a $\frac{1}{2}$ do dia 25 de junho de 2001, 16 a $\frac{1}{2}$ do dia 20 de julho de 2001, 24 a $\frac{1}{2}$ do dia 28 de janeiro de 2002, 16 a $\frac{1}{2}$ do dia 20 de maio de 2002 e 13 a $\frac{1}{2}$ do dia 17 de agosto de 2002.

É importante frisar que as imagens ASTER não cobrem individualmente toda

a área de estudo. O recobrimento pode variar entre duas a cinco imagens para cada estação pluviométrica.

Para as imagens MODIS, como foram utilizadas duas imagens, o acumulado de chuva de quatro dias (Ac4) correspondeu respectivamente ao acúmulo de chuva, em milímetros, dos dias 02, 03, 04, 05 e ½ do dia 06 de abril de 2002 e dos dias 19, 20, 21, 22 e ½ do dia 23 de abril de 2002.

Procurou-se utilizar em todas as análises dois grupos amostras: uma para modelagem e outra para verificação. Em alguns casos como o número de amostras era pequeno foram utilizadas somente as amostras para a modelagem. Isso ocorreu principalmente para os solos individuais B e H & I e para os sensores que dispunham de poucos dados para estes solos, como foi o caso do Landsat e algumas vezes do ASTER.

Após a modelagem, a seleção dos melhores resultados foi feita baseada, nos resultados das análises, nos resultados obtidos com o teste de Kolmogorov-Smirnov e na correlação dos resultados modelados com os resultados existentes.

Neste Capítulo é apresentada inicialmente a modelagem obtida para cada solo para o Landsat, posteriormente para o ASTER e depois para o MODIS. No final da descrição de cada sensor são apresentadas tabelas contendo os dados obtidos com a análise bem como com os testes de aderência e de correlação dos dados.

5.1 LANDSAT

5.1.1 Solo B

Foram utilizadas oito amostras para modelagem da imagem Landsat de 28 de novembro de 2002. É um número reduzido de amostras, porém mesmo assim foi possível realizar a modelagem. Optou-se por não realizar a verificação com as mesmas amostras para que o resultado não apresentasse vícios. As variáveis selecionadas foram: NDVI, Tasseled Cap – umidade e banda Termal.

Nesta primeira regressão múltipla realizada para o solo B, o resultado obtido mostra um modelo de regressão múltipla que descreve a relação entre a variável dependente Ac4 e as três variáveis independentes: NDVI, Tasseled - umidade (TU) e Termal (TER), expressa na equação (5.1).

$$Ac4 = 6,03716 - 52,7937*NDVI + 58,2225*TU + 323,572*TER \quad (5.1)$$

Nesta expressão nota-se a significância da variável “Termal” sobre as demais devido ao alto valor do seu coeficiente.

5.1.2 Solos H & I

Para o estudo do comportamento espectral dos solos H & I, agrupados devido às suas características geotécnicas, foram utilizadas dez amostras para modelagem e três amostras para a verificação dos resultados. A análise das variáveis independentes sugere que a combinação entre NDII, Tasseled Cap - umidade e banda Termal é a melhor para a determinação do acumulado de chuva nestes solos. Nota-se, porém que a regressão múltipla linear não é eficiente, por apresentar valores baixos de R-quadrático e R-quadrático absoluto. Após a utilização do algoritmo GMDH, com a aplicação de um polinômio de segundo grau os resultados foram melhorados.

O resultado mostra o modelo de regressão múltipla que as variáveis independentes NDII, Tasseled cap – umidade (TU) e Termal (TER) descrevem em relação a variável dependente Ac4 através da equação (5.2).

$$Ac4 = -106,094 - 29,4662*NDII + 81,4542*TU + 990,37*TER \quad (5.2)$$

Nesta equação, o coeficiente que acompanha a variável independente “Termal” é bem maior que o das demais.

5.1.3 Solos B, F & G

Em uma tentativa de agrupar paulatinamente os diferentes tipos de solo para se avaliar até que ponto e quais as características físicas dos mesmos que permitem ou

não que uma única modelagem seja realizada com sucesso, decidiu-se criar dois grandes grupos de solos. O primeiro composto pelos solos do tipo B, F e G que têm em comum algumas características geotécnicas (Capítulo 4). Com o agrupamento dos solos obtém-se também um número maior de amostras tanto para a modelagem como para a verificação, o que torna estatisticamente mais confiável o modelo.

Para a análise dos solos B, F e G foram utilizadas doze amostras para modelagem e cinco amostras para verificação. A análise das variáveis independentes sugere que a combinação entre a segunda componente principal (PC2), a componente Umidade da transformação Tasseled Cap (TU) e banda Termal (TER) é a melhor para a determinação do acumulado de chuva nestes solos.

$$Ac4 = -17,0897 + 77,3078*PC2 + 37,3439*TU + 258,77*TER \quad (5.3)$$

5.1.4 Solos D, E, H & I

Na modelagem do grupo de solos D, E, H & I quinze amostras foram utilizadas para a geração do modelo e cinco amostras foram utilizadas para a verificação. Como variáveis independentes indicadas pelo modelo, ou seja, aquelas que juntas apresentaram os melhores valores de R-quadrático e R-quadrático ajustado estão: NDII, Tasseled Cap-umidade e banda Termal, resultado similar ao obtido através das análises realizadas somente com os solos H&I.

O resultado mostra o modelo de regressão múltipla que descreve a relação entre a variável dependente Ac4, e as variáveis independentes através da equação (5.4).

$$Ac4 = -59,5847 - 29,464*NDII + 57,5445*TU + 576,762*TER \quad (5.4)$$

5.1.5 Todos os Tipos de Solos

Para o estudo do comportamento espectral de todos os tipos de solos as variáveis independentes indicadas pelo modelo como sendo aquelas que juntas

apresentaram os melhores valores de R-quadrático e R-quadrático ajustado foram: NDII, Tasseled Cap – umidade e banda Termal o mesmo indicado para o grupo de solos D, E, H e I.

Foram utilizadas vinte e sete amostras para a modelagem e dez amostras para a verificação do modelo. Porém nesta regressão múltipla optou-se por utilizar como variáveis independentes o índice NDII, Tasseled Cap – umidade e raiz quadrada da Banda Termal. Isso porque através de alguns testes realizados observou-se que a utilização da raiz quadrada da Banda Termal responde melhor do que a banda Termal unicamente.

O resultado mostra o modelo de regressão múltipla que descreve a relação entre a variável dependente Ac4, através da equação (5.5).

$$Ac4 = -114,439 - 6,65291 \cdot NDII + 34,212 \cdot TU + 353,179 \cdot \sqrt{TER} \quad (5.5)$$

5.1.6 Avaliação dos modelos para os dados Landsat

A TABELA 5.1 resume os valores da correlação para os diferentes modelos apresentados nos itens anteriores. Ao se analisar os dados obtidos através de regressão múltipla aplicada a imagem Landsat, observa-se que para o solo B a regressão realizada pode ser considerada satisfatória, pois apresenta o valor de R-quadrático (R^2) elevado, explicando mais que 90% da variabilidade do acumulado de chuva. Para os demais grupos de solo este valor decai abaixo de 70% e no caso da modelagem de todos os tipos de solo juntos este valor não atinge nem 50%. Ao nos referirmos ao R-quadrático ajustado (R^2 ajustado), que é mais conveniente para comparar modelos com números diferentes de variáveis independentes percebemos o mesmo comportamento.

O erro-padrão estimado, que mostra o desvio padrão do resíduo, e o erro médio absoluto (EMA), que é a media dos valores dos resíduos, também são menores para o solo B que para os demais tipos de solo (TABELA 5.1). Em todos os casos a significância estatística está entre 90% ou mais.

TABELA 5.1 –REGRESSÕES MÚLTIPLAS N° 1, REALIZADAS COM A IMAGEM LANDSAT

Tipo de Solo	Bandas	Sig. Est (%)	R ²	R ² AJUSTADO	ERRO PADRÃO	EMA
Solo B	NDVI, Tasseled, Termal	90	90,10	80,20	1,94	1,01
Solos H & I	NDII, Tasseled Termal	90	75,94	61,50	2,80	1,83
Solos B, F,G	PCA_2, Tasseled, Termal	95	70,88	59,96	2,72	1,74
Solos D, E, H & I	NDVI, PCA_1 Termal	95	62,15	50,80	3,22	2,12
Todos os Solos	NDII, Tasseled, Termal	99	44,12	36,83	3,73	2,76

O teste Kolmogorov_Smirnov (teste K-S) é aplicado para o estudo da igualdade estatística de duas populações. Ele procura diferenças entre a função de distribuição das duas populações baseada em suas amostras aleatórias independentes. Sua vantagem é que não há comprometimento do teste se a distribuição dos dados não for normal, pois se trata de um teste não-paramétrico e de distribuição livre, além disso, diferentemente do teste *t-student* ele pode ser aplicado no caso de amostras pequenas (CAPÍTULO 4). Considera-se neste caso que a hipótese nula:

$$H_0: \text{O valor modelado de } Ac4 \text{ é igual ao valor observado.}$$

A máxima diferença entre as frequências acumuladas de cada população de amostras (D_{\max}) é o termo estatístico utilizado para avaliar o desempenho do teste. Se este valor for superior ao valor crítico ($D_{\max} \geq D_{\text{crítico}}$) rejeita-se a hipótese de igualdade das amostras.

A TABELA 5.2 traz os resultados obtidos com o teste K-S para a imagem Landsat para os diferentes grupos de solos. Percebe-se que somente para a modelagem realizada para o grupo de solos D, E, H e I e para todos os tipos de solos é que a hipótese é rejeitada. Isso coincide com o resultado apresentado pela correlação entre os dados de acumulado de chuva modelados e os dados observados. Na correlação somente a modelagem do solo B apresentou-se superior a 80%. A última coluna da

TABELA 5.2 traz o resultado da correlação aplicada nas amostras utilizadas para a verificação do modelo. Nela é visto que somente a modelagem realizada para o grupo de solos B, F e G apresenta uma correlação superior a 80%

TABELA 5.2 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, LANDSAT, 1° REGRESSÃO

Tipo de Solo	Teste K-S		Correlação	
	<i>D</i>	<i>D_{crítico}</i>	<i>Modelo</i>	<i>Val.</i>
Solo B	0.25	0.43	0,86	-
Solos H & I	0.40	0.54	0,85	0,07
Solos B, F,G	0.15	0.48	0,74	0,89
Solos D, E,H&I	0.47	0.44	0,65	0,42
Todos os Solos	0.37	0.33	0,66	0,45

A partir dos dados apresentados pode-se concluir que somente a modelagem realizada para o solo B pode ser considerada satisfatória, sendo a modelagem realizada para o grupo de solos H & I e B, F e G, considerada regular e a modelagem realizada para os grupos D,E,H &I e todos os solos pode ser considerada imprópria.

5.2 ASTER

As imagens aqui utilizadas correspondem a Reflectância de Superfície e abrangem a região do infravermelho do espectro eletromagnético (SWIR1 a SWIR6) e a Temperatura Superficial (TS), além disso, foram utilizados também os índices adaptados as imagens ASTER: NDVI, NDII e Tasseled Cap- umidade (TU).

5.2.1 Solo B

Para o estudo do comportamento espectral do solo B a análise das variáveis independentes sugere que a combinação entre NDII, NDVI, SWIR3, SWIR5, e SWIR6 e Temperatura Superficial (TS) é a melhor para a determinação do acumulado de chuva neste solo. Porém, esta combinação de variáveis apresentou colinearidade nos resíduos. Desta forma uma nova regressão foi feita retirando-se as variáveis NDII e SWIR5, que apresentaram as maiores correlações com as outras bandas.

Foram utilizadas nove amostras para modelagem e, devido ao pequeno

número de amostras, não se separou amostras para a verificação dos resultados.

O resultado mostra o modelo de regressão múltipla que descreve a relação entre a variável dependente (Ac4) e as variáveis independentes expressa na equação (5.6).

$$Ac4 = 312,545 - 26,9384*NDVI + 244,258*SWIR3 - 257,875*SWIR6 - 94,083*TS \quad (5.6)$$

A equação mostra um equilíbrio entre as variáveis independentes com uma leve valorização das variáveis SWIR3 e SWIR6.

5.2.2 Solo H & I

Para a modelagem dos solos H & I foram utilizadas 10 amostras sendo 7 para a modelagem e 3 para a verificação do modelo. Na análise das variáveis independentes foram indicadas como as mais adequadas à identificação da umidade as variáveis: SWIR1, SWIR3, SWIR5 e SWIR6, PC1 e TS, porém esta combinação também apresentou colinearidade e buscou simplificá-la restando as variáveis SWIR5 e TS.

O resultado mostra o modelo de regressão múltipla que descreve a relação entre a variável dependente (Ac4) e as variáveis independentes, através da equação (5.7).

$$Ac4 = 204,64 - 63,2057*TS - 50,254*SWIR5 \quad (5.7)$$

5.2.3 Solos B, F & G

Para análise dos solos B, F e G, agrupados devidos as suas características geotécnicas, foram escolhidos 8 amostras para a modelagem e não foram selecionadas amostras para a verificação do modelo. As variáveis independentes apontadas como melhores na determinação da umidade para este grupo de solos são: SWIR3, SWIR5 e NDVI.

O resultado mostra o modelo de regressão múltipla que descreve a relação

entre a variável dependente (Ac_4) e as variáveis independentes, através da equação (5.8).

$$Ac_4 = 51,5917 - 71,5107 \cdot NDVI + 885,027 \cdot SWIR3 - 1055,64 \cdot SWIR5 \quad (5.8)$$

Esta equação destaca a importância das variáveis SWIR3 e SWIR5 na determinação da umidade.

5.2.4 Solos D, E, H & I

Para as análises do grupo de solos D, E, H & I foram utilizadas treze amostras para modelagem e seis amostras para verificação. As análises que envolveram os solos H & I apontaram como variáveis independentes mais sensíveis à umidade a temperatura superficial (TS), as leituras das bandas do infravermelho termal (SWIR2, SWIR4, SWIR5) e a banda de umidade da transformação Tasseled Cap (TU). Por isto, elas foram inicialmente utilizadas nas modelagens para o grupo de solos D, E, H & I, porém fazendo-se a análise do modelo mais efetivo as variáveis independentes selecionadas foram: TS, SWIR2, SWIR5, NDII e TU.

O resultado mostra o modelo de regressão múltipla que descreve a relação entre a variável dependente (Ac_4) e as variáveis independentes, através da equação (5.9).

$$Ac_4 = 237,718 - 37,771 \cdot NDII - 55,098 \cdot TS - 906,937 \cdot SWIR2 + 537,218 \cdot SWIR5 - 40,959 \cdot TU \quad (5.9)$$

Pelos valores dos coeficientes apresentados nesta equação nota-se a importância da variável SWIR2 e SWIR5 na determinação da umidade.

5.2.5 Todos os Tipos de Solos

Para o estudo do comportamento espectral de todos os tipos de solos a combinação entre as variáveis NDVI, TS, SWIR1, SWIR3 e SWIR5 é a mais eficiente na determinação da umidade. Foram utilizadas dezenove amostras para o

desenvolvimento do modelo e oito amostras para sua verificação. O resultado mostra o modelo de regressão múltipla que as variáveis independentes descrevem em relação a variável dependente Ac4 na equação (5.10).

$$\begin{aligned} \text{Ac4} = & 189,053 - 31,685 * \text{NDVI} - 53,693 * \text{TS} + 167,318 * \text{SWIR1} - 619,194 * \text{SWIR3} \\ & + 414,63 * \text{SWIR5} \end{aligned} \quad (5.10)$$

Nesta equação nota-se a importância das variáveis SWIR3 e SWIR5 para a modelagem.

5.2.6 Avaliação dos modelos para os dados ASTER

Ao se analisar os dados obtidos através de regressão múltipla aplicada as imagens ASTER observa-se em todos os casos o valor de R-quadrático (R^2) é superior a 80%, ou seja, todos os modelos gerados explicam mais do que 80% da variabilidade do acumulado de chuva de quatro dias (Ac4). Ao se referir ao R-quadrático ajustado (R^2 ajustado), que é mais conveniente para comparar modelos com números diferentes de variáveis independentes, percebe-se que somente a modelagem realizada para os solos H & I situa-se abaixo de 80% e mesmo assim atinge 73%.

O erro-padrão estimado, que mostra o desvio padrão do resíduo e o erro médio absoluto (EMA) que é a média dos valores dos resíduos, também são menores na modelagem dos solos D, E, H & I, o que coincide com os melhores resultados obtidos para o R-quadrático e R-quadrático ajustado (TABELA 5.3).

TABELA 5.3 –REGRESSÕES MÚLTIPLAS N° 1, REALIZADAS COM AS IMAGENS ASTER

Tipos de Solos	Bandas	Sig. Est. (%)	R^2	R^2 AJUSTADO	ERRO PADRÃO	EMA
Solo B	NDVI, SWIR3, SWIR6 e TS	95	93,17	86,33	4,08	2,12
Solo H & I	SWIR5 e TS	95	82,40	73,60	5,19	2,48
Solos B, F,G	NDVI, SWIR3, SWIR5,	99	93,50	88,60	4,07	2,44
Solos D, E, H&I	NDII, TS, SWIR2, SWIR5, TU	99	97,15	95,11	2,02	1,40
Todos os Solos	NDVI, TS, SWIR1, SWIR3, SWIR5	99	88,90	84,70	3,03	1,97

Aplicou-se a cada caso, o teste Kolmogorov_Smirnov (teste K-S), considerando a hipótese nula:

$$H_0: \text{valor modelado de } Ac4 \text{ igual ao valor observado.}$$

A TABELA 5.4 traz os resultados obtidos com o teste K-S para as imagens ASTER para os diferentes grupos de solos. Observa-se que em todas as modelagem a hipótese nula é aceita.

Na TABELA 5.4, o valor da correlação entre os valores observados e modelados, para as amostras usadas no modelo e para o conjunto de validação, é mostrado. Em todos os modelos, a correlação dos dados usados na modelagem está acima de 90% o que revela que os modelos conseguem representar a relação entre as variáveis. Porém, ao analisar a correlação para as amostras de verificação, percebe-se que, principalmente na modelagem de todos os tipos de solos juntos e do grupo de solos D, E, H & I, esse valor decai para cerca de 50%. Ou seja, a eficiência do modelo para simular outras amostras diferentes àquelas usadas na modelagem é baixa.

TABELA 5.4 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, ASTER, 1° REGRESSÃO

Tipo de Solo	Teste K-S		Correlação	
	D	D _{crítico}	Modelo	Val.
Solo B	0.29	0.46	0,96	-
Solos H & I	0.29	0.46	0,91	0,95
Solos B, F,G	0.22	0.43	0.96	-
Solos D, E, H&I	0.31	0.48	0,99	0,58
Todos os Solos	0.26	0.39	0,94	0,52

Os dados da primeira regressão múltipla para as imagens ASTER revelam êxito em todas as modelagem muito embora o resultado de algumas verificações não tenham sido ótimos, eles refletem a heterogeneidade espectral que estes grupos apresentam.

5.3 MODIS

Para a caracterização espectral das imagens MODIS foram utilizadas como

variáveis independentes as 7 bandas correspondentes à reflectância de superfície, com resolução de 500m, e a banda de temperatura superficial noturna (TSN). Como se dispunha de poucos dados da banda de temperatura superficial diurna esta variável foi descartada (CAPÍTULO 4).

5.3.1 Solo B

Para a modelagem do solo B através de regressão múltipla aplicada as imagens MODIS foram utilizadas treze amostras para a modelagem e não foram utilizadas amostras para a verificação do modelo.

Neste trabalho as sete primeiras bandas do MODIS são denominadas respectivamente de M1,M2, ..., M7.

Para o solo B as variáveis independentes selecionadas foram: M4, M5, M6 e a banda de Temperatura Superficial Noturna (TSN). O resultado, expresso na equação (5.11), mostra o modelo de regressão múltipla que as variáveis independentes descrevem em relação a variável dependente Ac4:

$$Ac4=5529,73-838,459*M4+636,988*M5+492,073*M6-4044,58*TSN \quad (5.11)$$

Nesta equação nota-se a importância da variável Temperatura Superficial Noturna para a expressão.

5.3.2 Solos H & I

Para o estudo do comportamento espectral dos solos H & I, agrupados devido às suas características geotécnicas, foram utilizadas treze amostras para a modelagem e novamente não foram utilizadas amostras para a verificação do modelo.

A análise das variáveis independentes sugere que a combinação entre as bandas M1, M4, M6, M7 e Temperatura Superficial Noturna (TSN) é a melhor para a determinação do acumulado de chuva nestes solos. Nesta regressão múltipla o resultado obtido mostra um modelo que descreve a relação entre a variável dependente Ac4 e as variáveis independentes através da equação (5.12).

$$Ac4 = 9046,97 - 2490,4 * M4 + 1081,22 * M6 - 964,221 * M7 + 2373,12 * M1 - 6447,38 * TSN \quad (5.12)$$

Esta equação valoriza as variáveis TSN, M1 e M4 na determinação da umidade.

5.3.3 Solos B, F & G

Para a análise dos solos B, F e G foram utilizadas doze amostras para a modelagem e quatro amostras para a verificação. Nesta primeira regressão múltipla, realizada para os solos B, F e G, foram utilizadas as variáveis independentes correspondentes às bandas M1, M2, M4, M7 bem como a Temperatura Superficial Noturna (TSN), como sugerido pela seleção do melhor modelo realizado no início de todas as análises. O resultado apresentado na equação (5.13) mostra o modelo de regressão múltipla que as variáveis independentes descrevem em relação a variável dependente Ac4:

$$Ac4 = 2459,9 - 2398,4 * M1 - 474,379 * M2 + 2128,86 * M4 + 938,806 * M7 - 89,54 * TSN \quad (5.13)$$

5.3.4 Solos D, E, H & I

Na modelagem dos solos D, E, H & I vinte amostras foram utilizadas: 14 na modelagem e 6 amostras para verificação do modelo. As bandas M3, M4, M5 e a temperatura superficial noturna (TSN) foram selecionadas como as melhores variáveis independentes. Quando somente os solos H&I foram analisados as bandas M4, M6, M7 e a temperatura superficial noturna (TSN) foram escolhidas. O resultado mostra o modelo de regressão múltipla que as variáveis independentes descrevem em relação a variável dependente Ac4 como indica a equação (5.14).

$$Ac4 = 6128,18 - 685,78 * M3 + 667,187 * M4 + 197,896 * M5 - 4395,41 * TSN \quad (5.14)$$

Quando uma segunda regressão foi realizada utilizando-se o quadrado da temperatura superficial noturna (TSN^2) ao invés da temperatura superficial (TS) os resultados foram praticamente os mesmos, sem melhora ou piora nos valores de R-quadrático, R-quadrático ajustado e do erro-padrão.

5.3.5 Todos os Tipos de Solos

Na modelagem de todos os tipos de solo para as imagens MODIS foram utilizadas 22 amostras para a geração do modelo e 11 amostras para a sua verificação. As variáveis indicadas para a melhor modelagem são as bandas M1, M4, M5, M7 e TSN. Notou-se que um bom resultado também é obtido excluindo-se a banda 7 (M7), pois ela não oferece confiança estatística de 90%.

Nesta regressão múltipla realizada para todos os tipos de solos, o resultado obtido mostra um modelo que descreve a relação entre a variável dependente Ac_4 e as variáveis independentes através da equação (5.15).

$$Ac_4 = 2477,32 + 414,479 * M1 - 511,606 * M4 + 212,356 * M5 - 1771,94 * TSN \quad (5.15)$$

Esta modelagem foi realizada também contendo entre a variável independente M7. Com a presença desta banda há um aumento do R-quadrático (73,46%), porém uma redução no valor de R-quadrático ajustado (68,58%). Com a variável M7 não oferece confiança estatística de 90% optou-se por não incluí-la no modelo.

5.3.6 Resultados Obtidos para as Imagens MODIS

Ao analisar os dados obtidos através de regressão múltipla aplicada as imagens MODIS observa-se em todos os casos o valor de R-quadrático (R^2) é superior a 80%, ou seja, todos os modelos gerados explicam mais do que 80% da variabilidade do acumulado de chuva de quatro dias (Ac_4). Com referência ao R-quadrático ajustado (R^2 ajustado), que é mais conveniente para comparar modelos com números diferentes

de variáveis independentes, percebe-se que somente a modelagem realizada para os todos os tipos de solos juntos situa-se abaixo de 80% e mesmo assim atinge 70% (TABELA 5.5).

O erro-padrão estimado, que mostra o desvio padrão do resíduo, e o erro médio absoluto (EMA), que é a média dos valores dos resíduos, também são mais elevados se comparados às análises realizadas com as imagens Landsat e ASTER mais isso pode ser reflexo da maior variabilidade dos dados encontrada neste sensor. Os demais sensores (Landsat e ASTER) apresentam uma amplitude menor da variabilidade do acumulado de chuvas (Ac4) e inclusive em seu valor absoluto - no caso da imagem Landsat não se dispunha de valores elevados de acumulado de chuva, conseqüentemente a variabilidade dos resíduos é menores na modelagem das imagens Landsat e ASTER.

TABELA 5.5 –REGRESSÕES MÚLTIPLAS N° 1, REALIZADAS COM AS IMAGENS MODIS

Solos	Bandas	Sig. Est. (%)	R ²	R ² AJUSTADO	ERRO PADRÃO	EMA
Solo B	M4, M5, M6, TSN	95	93,69	87,34	11,04	5,80
Solos H & I	M1, M4, M6, M7, TSN	90	91,47	84,35	11,37	5,96
Solos B, F,G	M1, M2, M4, M7, TSN	99	96,17	92,96	5,42	2,81
Solos D, E, H&I	M3, M4, M5, TSN	99	86,38	80,32	12,71	8,72
Todos os Solos	M1, M4, M5, TSN	99	75,75	70,04	13,23	9,50

Quanto aos resultados obtidos com o teste de Kolmogorov-Smirnof (K-S) para as imagens MODIS (TABELA 5.6), observa-se que em todos os casos os valores obtidos para o D_{\max} são inferiores aos valores do $D_{\text{crítico}}$. Esses resultados também são confirmados pelos dados de correlação entre os valores observados e os valores obtidos. A correlação dos dados envolvidos na modelagem é, em todos os casos, superior a 80%, o que revela uma boa modelagem. Ao analisar a correção calculada a partir das amostras de verificação, percebe-se que principalmente na modelagem de todos os tipos de solos juntos e do grupo de solos D, E, H & I esse valor é igual ou superior a 80%.

TABELA 5.6 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, MODIS, 1° REGRESSÃO

Tipo de Solo	Teste K-S		Correlação	
	<i>D</i>	<i>D_{crítico}</i>	Modelo	Val.
Solo B	0.23	0.48	0,80	–
Solo H & I	0.23	0.48	0,90	–
Solos B, F,G	0.17	0.50	0,98	0,20
Solos D, E, H&I	0.27	0.46	0,92	0,80
Todos os Solos	0.23	0.37	0,87	0,85

Estes resultados apontam que a análise de regressão múltipla foi eficiente na modelagem do acumulado de chuva (Ac4) para as imagens MODIS.

6 APLICAÇÃO DO ALGORITMO GMDH

Na aplicação do algoritmo GMDH para a modelagem do acumulado de chuva utilizou-se inicialmente todas as variáveis independentes, porém posteriormente buscou-se fazer uma segunda análise utilizando-se somente as variáveis independentes sugeridas pelos resultados da primeira série de experimentos com a regressão múltipla. Isso foi feito para se comparar a capacidade de seleção das duas metodologias.

Em todas as análises permitiu-se que o polinômio se desenvolva até o 3º grau e em alguns casos não se utilizou amostras para verificação devido ao pequeno número de amostras disponíveis. Em cada análise foram gerados três modelos, mas somente aquele cujo critério geral é mais baixo (CAPÍTULO 4) foi selecionado e aqui apresentado.

Segue nesta análise a metodologia que modela inicialmente os solos individualmente, solos do tipo B e H & I, posteriormente buscou-se modelar dois grupos distintos de solos (B, F & G) e (D, E, H & I) e finalmente realizou-se a modelagem utilizando-se dados de todos os solos simultaneamente para todos os três sensores: Landsat, ASTER e MODIS.

6.1 LANDSAT ETM

6.1.1 Solo B

Para análise do solo B através do algoritmo GMDH foram utilizadas oito amostras para modelagem. Nesta primeira análise as variáveis selecionadas pelo algoritmo foram o índice de vegetação NDVI, a primeira componente principal (PC1) e Banda Termal (TER), expressas na equação (6.1).


$$Ac4 = 35.453382 * NDVI * PC1 + 441.084549 * TER^2 \quad (6.1)$$

Como a modelagem foi realizada sem uma prévia seleção das variáveis

independentes estas variáveis se diferem daquelas obtidas através da regressão múltipla (CAPÍTULO 5).

O GRÁFICO 6.1 mostra a relação entre os valores obtidos com o modelo e os valores observados. Através deste gráfico evidencia-se a dificuldade de modelar os valores mais elevados do acumulado de chuva (Ac4).

GRÁFICO 6.1 – RELAÇÃO ENTRE VALORES OBTIDOS E VALORES OBSERVADOS, LANDSAT, SOLO B




Uma segunda análise utilizando o algoritmo GMDH utilizou como variáveis independentes somente NDVI, a componente umidade da transformação Tasseled Cap (TU) e Banda Termal (TER), determinadas através da regressão múltipla. Nesta modelagem a equação (6.2) foi a que apresentou o melhor critério geral. Na equação proposta, vê-se a importância da banda termal.

$$Ac4 = -9.25907 + 174.960967 \cdot TU \cdot TER + 1213.240506 \cdot TER^2 \quad (6.2)$$

O GRÁFICO 6.2 mostra a relação entre os valores obtidos com o este outro modelo e os valores observados.

Nesta segunda análise o critério geral é mais baixo o que reflete na modelagem dos valores de Ac4. Vê-se, por exemplo, que os valores mais altos do acumulado de chuva são mais bem modelados nesta análise do que na anterior, desta forma a substituição das variáveis NDVI e PC1 pela variável TU mostrou-se eficiente na melhoria do modelo.

GRÁFICO 6.2 — RELAÇÃO ENTRE VALORES OBTIDOS E VALORES OBSERVADOS, LANDSAT, SOLO B




6.1.2 Solos H & I

Para o estudo do comportamento espectral dos solos H & I, agrupados devido às suas características geotécnicas, foram utilizadas dez amostras para modelagem e três amostras para a verificação dos resultados. Nesta primeira modelagem o algoritmo GMDH selecionou como variáveis independentes NDVI, NDII e PC1, expresso através da equação (6.3).

$$Ac4 = 4.63623 * NDVI + 3308.6996 * NDII * PC1 - 6719.538 * NDVI * NDII * PC1 \quad (6.3)$$

A relação entre os valores obtidos com a modelagem e os valores observados podem ser observados no GRÁFICO 6.3. Nele, observa-se que a modelagem obtida não foi satisfatória.

GRÁFICO 6.3 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS, LANDSAT SOLOS H&I




Em uma segunda análise com o algoritmo GMDH utilizou-se como variáveis independentes somente os índices NDII, a componente umidade da transformação Tasseled Cap (TU) e a banda termal TER. A equação (6.4) descreve o modelo gerado. Neste caso permitiu-se que o polinômio criado atingisse o quarto grau. Porém, o critério geral obtido foi mais alto do que na análise anterior.

$$Ac4 = -45.112597 * TER - 17.922352 * TU^2 + 497.991876 * TER^2 \quad (6.4)$$

O GRÁFICO 6.4 mostra a relação entre os valores obtidos com o modelo e os valores observados. Novamente a modelagem obtida não foi satisfatória, pois nivelou todos os valores do acumulado de chuva.

GRÁFICO 6.4 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS, LANDSAT, SOLOS H&I




6.1.3 Solos B, F & G

Para a análise dos solos B, F e G foram utilizadas doze amostras para modelagem e cinco amostras para verificação. O algoritmo GMDH selecionou como variáveis independentes a combinação que inclui: NDII, Banda Termal (TER), a componente umidade da transformação Tasseled Cap (TU), e as duas primeiras componentes principais PC1 e PC2, sendo que das bandas originalmente geradas para a imagem Landsat somente o NDVI não foi incluída. Dentre os modelos gerados o que obteve menor critério geral é o expresso pela equação (6.5)

$$Ac4 = -4.041281 * NDII + 66.896598 * TER - 62.25063 * TU * PC1 - 361.021586 * PC2^2 \quad (6.5)$$

No GRÁFICO 6.5 observa-se a relação entre os valores modelados (A) e os valores observados de Ac4. Em (B) vê a relação entre os valores obtidos (amostras de verificação) e os valores observados. Observa-se que os valores mais elevados do acumulado de chuva (Ac4) não foram bem modelados em ambos os casos.

GRÁFICO 6.5 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS. EM **A** VALORES MODELADOS, EM **B** VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, SOLOS B,F & G



Em uma segunda análise, utilizando-se o algoritmo GMDH, as variáveis independentes utilizadas foram aquelas apontadas na regressão múltipla: componente umidade da transformação Tasseled Cap (TU), PC2 e Banda Termal (TER). Embora se tenha permitido que o algoritmo atingisse até o 3º grau do polinômio, a equação (6.6) selecionada como a que melhor modela o acumulado de chuva apresenta um polinômio de 2º grau. A variável TER foi descartada no processo iterativo.


$$Ac4 = -113.33466 * TU - 287.63656 * TU^2 - 260.1589 * TU * PC2 \quad (6.6)$$

O critério geral desta segunda análise realizada com o algoritmo GMDH é mais baixo do que na primeira análise, porém ao se observar os valores do K-S (TABELA 6.2) os resultados da primeira são melhores.

O GRÁFICO 6.6 mostra a relação entre os valores obtidos com o modelo e

os valores observados. Embora os resultados ainda não possam ser considerados bons, percebe-se que a modelagem foi muito mais eficiente nesta segunda análise, porém, as amostras utilizadas para a verificação foram melhor modeladas pela primeira equação.

GRÁFICO 6.6 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS. EM **A** VALORES MODELADOS, EM **B** VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, SOLOS B,F & G



6.1.4 Solos D, E, H & I


Na modelagem do grupo de solos D, E, H & I, quinze amostras foram utilizadas para a geração do modelo e cinco amostras foram utilizadas para a verificação deste modelo. Nesta primeira análise as variáveis independentes selecionadas pelo algoritmo GMDH foram NDVI e TU (componente umidade). Dentre os modelos gerados o que apresentou o critério geral e de validação mais baixos foi o expresso pela equação (6.7).

$$Ac4 = 9.653349 * NDVI + 30.541931 * NDVI * TU \quad (6.7)$$

Observa-se a modelagem gerou uma equação simples onde não aparece a banda termal como variável independente, isso ocorreu mesmo permitindo que o polinômio atingisse o 3º grau.

Os resultados ilustrados no GRÁFICO 6.7 indicam que o algoritmo não conseguiu uma boa modelagem para os valores de acumulado de chuva (Ac4) mais elevados, como é o caso de 12.6 mm que foi modelado em 1.65mm.

GRÁFICO 6.7 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT , SOLOS D,E,H&I.



Experimentou-se fazer nova análise utilizando somente as variáveis independentes: NDII, Componente Umidade da transformação Tasseled Cap e a banda termal (TER), sugeridas pela regressão múltipla. O resultado obtido está expresso na equação (6.8). Mas o que se observa novamente é que os valores maiores de Ac4 não são bem modelados, gerando um resultado insatisfatório.

$$Ac4 = -11.211789 * TU - 24.567535 * NDII * TU \quad (6.8)$$

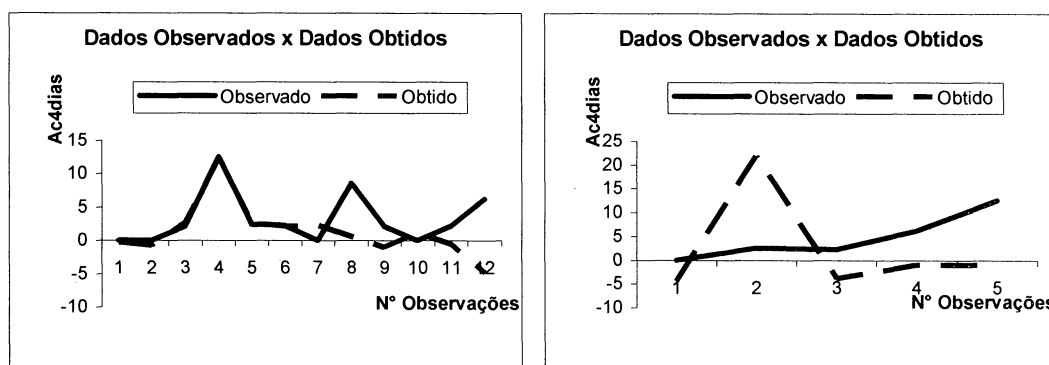
Ainda experimentou-se realizar as análises excluindo-se o solo I deste grupo por tratar-se de um solo com características geotécnicas muito variáveis. Neste caso, como se excluiu o solo I o número de amostras tanto para modelagem como para a verificação diminuiu assim nesta análise foram utilizadas 7 amostras para modelagem e duas para a verificação do modelo. A equação (6.9) foi a que obteve um critério geral e de validação mais baixos.

$$Ac4 = -115.73445 * NDII^2 - 20.83343 * PC2 - 21541.17002 * NDII * PC2 + 48831.61969 * NDVI * NDII * PC2 \quad (6.9)$$

O GRÁFICO 6.8 ilustra a relação entre os valores obtidos com a equação 6.9 e os valores observados de Ac4. Observa-se que a modelagem resultante nesta segunda

análise é muito mais eficiente do que as modelagens anteriores, pois consegue modelar os valores mais altos de Ac4. Evidentemente há um número reduzido de amostras o que a torna mais simplificada e as amostras utilizadas para a verificação do modelo (GRÁFICO 6.8 B) não indicam boa modelagem.

GRÁFICO 6.8 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, SOLOS D,E,H&I



A

B


6.1.5 Todos os tipos de Solos

Para o estudo do comportamento espectral de todos os tipos de solos foram utilizadas quinze amostras para a modelagem e dez amostras para a verificação do modelo. Nesta primeira análise para todos os tipos de solo as variáveis selecionadas pelo algoritmo GMDH foram: NDVI, PC2, NDII e PC1. O modelo que obteve menor critério geral e de validação foi o expresso através da equação (6.10).

$$Ac4 = 19.7118 \cdot NDVI^2 - 112.56311 \cdot PC2 - 152.44216 \cdot NDII \cdot PC1 - 999.43759 \cdot NDII \cdot PC2 \quad (6.10)$$

Nota-se que o coeficiente que multiplica o produto entre NDII e PC2 é maior que os demais, o que confere a estas duas variáveis grau de importância elevado nesta modelagem. O GRÁFICO 6.9 ilustra a relação entre os dados obtidos com esta modelagem e os dados observados de Ac4. Nele, é visível a dificuldade de modelar os valores maiores de Ac4 tais como 15.1mm e 12.6mm.

GRÁFICO 6.9 – RELAÇÃO ENTRE OS VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS. EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, TODOS OS TIPOS DE SOLOS



A


B

Posteriormente foi realizada uma segunda análise utilizando-se somente as variáveis determinadas *a priori*, pela regressão múltipla, como as mais suscetíveis à umidade. Assim somente os índices NDII, Componente Umidade da transformação Tasseled Cap (TU) e a banda termal (TER) foram utilizados nesta segunda análise, o resultado foi a equação (6.11) que apresenta só a banda Termal como variável independente.

$$Ac4 = 434.799666 * (TER^2) \quad (6.11)$$

O GRÁFICO 6.10 evidencia uma modelagem que não se resultou boa, com uma distribuição linear dos dados, diversa ao da distribuição original.

GRÁFICO 6.10 – VALORES OBTIDOS PELO ALGORITMO GMDH E OS VALORES OBSERVADOS. EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO, LANDSAT, TODOS OS TIPOS DE SOLOS



A

B

6.1.6 Resultados Gerais obtidos para o Landsat ETM+ através do GMDH

Através da TABELA 6.1 observa-se os dados obtidos com as modelagens geradas pelo algoritmo GMDH para a imagem Landsat. Como ao utilizar o algoritmo GMDH são gerados diferentes modelos, a escolha do melhor modelo acaba sendo baseada no critério geral mais baixo. Porém o critério deve ser avaliado dentro do mesmo grupo de amostras, pois seu valor pode variar de acordo com o número de amostras utilizadas. A TABELA 6.1 indica quais foram as variáveis independentes selecionadas pelo algoritmo, podemos perceber uma presença freqüente da banda Termal ao quadrado, indicando a importância desta variável na determinação da umidade do solo.

TABELA 6.1 –MODELAGENS COM ALGORITMO GMDH, REALIZADAS COM A IMAGEM LANDSAT

Solo	Algoritmo	Variáveis Indep. Utilizadas	Variáveis Indep. Selecionadas	Critério Geral
Solo B	GMDH_1	todas	NDVI, PC1, TER ²	13.75
	GMDH_2	NDVI, TU TER	TU*TER, TER ²	8.06
Solos H & I	GMDH_1	todas	NDVI, NDII*PC1, NDVI*NDII*PC1	2.54
	GMDH_2	NDII, TU TER	TER, TU ² , TER ²	4.15
Solos B, F, G	GMDH_1	Todas	NDII, TER, TU*PC1, PC2 ²	3.74
	GMDH_2	TU, PC2 TER	TU, TU ² , TU*PC2	2.64
Solos D, E, H & I	GMDH_1	Todas	NDVI, NDVI*TU	3.04
	GMDH_2	NDII, TU TER	TU, NDII*TU	10.24
Todos os Solos	GMDH_1	Todas	NDVI ² , PC2, NDII*PC1	11.30
	GMDH_2	NDII, TU, TER	NDII*PC2 TER ²	22.45

A TABELA 6.2 traz os resultados obtidos com o teste K-S para a imagem Landsat para os diferentes grupos de solos através do algoritmo GMDH. Percebe-se que somente para a segunda modelagem realizada para o grupo de solos D, E, H & I e a segunda modelagem de todos os tipos de solos é que a hipótese nula é rejeitada. Porém, ao se analisar os valores de correlação percebe-se que somente a segunda modelagem realizada para o solo B e a segunda modelagem realizada para os solos H & I possuem correlação superior a 75%. Isso demonstra que as modelagem realizadas com o algoritmo GMDH não foram eficientes na modelagem do acumulado de chuva

para imagem Landsat.

TABELA 6.2 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, LANDSAT, ALGORITMO GMDH

Tipo de Solo	Teste K-S		Correlação	
	<i>D</i>	<i>D_{crítico}</i>	Modelo	Valid
Solo B	0.25	0.43	0.59	-
	0.25	0.43	0.89	-
Solo H & I	0.2	0.54	0.67	-
	0.5	0.54	0.78	-
Solos B, F, G	0.31	0.48	0.64	0.60
	0.31	0.48	0.62	0.60
Solos D, E, H&I	0.27	0.44	0.19	0.40
	0.45	0.44	-0.36	-0.35
Todos os Solos	0.22	0.33	0.36	-0.06
	0.48	0.33	0.43	0.24

6.2 ASTER


6.2.1 Solo B

Para o estudo do comportamento espectral do solo B foram utilizadas entre sete e nove amostras para modelagem. Devido ao pequeno número de amostras, neste caso, não se separou amostras para a verificação dos resultados. Na primeira análise realizada com o algoritmo GMDH entre os modelos gerados aquele que obteve um critério geral e de validação mais baixos foi o expresso através da equação (6.12).

$$Ac4=66831.704*SWIR6^2-2664.493*SWIR6^2*TS+6806.124*SWIR6^2*TS^2 \quad (6.13)$$

O modelo obtido sugere a importância da banda do infravermelho médio (SWIR6) na determinação da umidade. O GRÁFICO 6.11 mostra a relação entre os valores obtidos com o modelo e os valores observados. Nota-se, porém que o valor mais elevado do acumulado de chuva não foi bem modelado nesta análise.

GRÁFICO 6.11 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS



6.2.2 Solo H & I


Para a modelagem dos solos H & I foram utilizadas 10 amostras sendo 7 para a modelagem propriamente dita e 3 para a verificação do modelo. Nesta primeira análise foi selecionada como variável independentes pelo algoritmo GMDH somente a Temperatura Superficial (TS), como pode ser observado na equação (6.14). Dentre os modelos gerados aquele que obteve um critério geral e um critério de validação mais baixos foi:

$$Ac4 = 122.39044 - 39.261213 * TS \quad (6.14)$$

O Modelo obtido sugere a importância da variável Temperatura Superficial na determinação da umidade. O GRÁFICO 6.12 mostra a relação entre os valores obtidos com o modelo e os valores observados. Neste caso, o valor mais elevado do acúmulo de quatro dias (Ac4), que é de 25.6mm, não foi bem modelado.

Nesta segunda análise o critério geral é mais baixo o que reflete na modelagem dos valores de Ac4. Vê-se, por exemplo, que os valores mais altos do acumulado de chuva são mais bem modelados nesta análise do que na anterior, desta forma a substituição das variáveis NDVI e PC1 pela variável TU mostrou-se eficiente na melhoria do modelo.

GRÁFICO 6.12 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS



Quando foram utilizadas as variáveis independentes indicadas pela regressão múltipla, ou seja, SWIR1, SWIR3, SWIR5 e SWIR6 e PC1 e TS, o resultado pelo GMDH obtido foi o mesmo.


Em uma segunda análise foram utilizadas como variáveis independentes: SWIR2, SWIR4, SWIR5 além da Temperatura Superficial (TS) e da componente Umidade da transformação Tasseled Cap (TU). Dentre os modelos gerados aquele que obteve um critério geral e um critério de validação mais baixos foi o expresso pela equação (6.15). O modelo obtido sugere a importância da variável SWIR2 na determinação da umidade.

$$Ac4 = 497.53741 * SWIR2 - 58.416499 * SWIR5 * TS^2 \quad (6.15)$$

Nesta análise em relação à desenvolvida anteriormente retiraram-se da modelagem as variáveis independentes: SWIR1 e SWIR6 isso deu destaque as variáveis SWIR2 e SWIR5 que antes não apareciam na expressão, especialmente destaca-se SWIR2.

O GRÁFICO 6.13 mostra a relação entre os valores obtidos com o modelo e os valores observados. Novamente, aqui ocorre a dificuldade em se modelar os valores mais elevados do Ac4, porém já se observa um resultado melhor que o obtido na modelagem anterior.

GRÁFICO 6.13 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS



6.2.3 Solos B, F & G


Para análise dos solos B, F e G foram escolhidas 4 amostras para verificação e 13 amostras para a modelagem. As variáveis independentes apontadas como melhores na determinação da umidade para este grupo de solos através do algoritmo GMDH foram: SWIR4, SWIR6, TS.

Dentre os modelos gerados destaca-se o expresso na equação (6.16), por apresentar menores valores de critério geral e de critério de validação. O modelo obtido sugere a importância das variáveis SWIR4, SWIR6 e da TS na determinação da umidade.

$$Ac4 = 6864.2226 * SWIR6 - 2731.3338 * SWIR4 * TS - 2235.039 * SWIR6 * TS + 889.3414 * SWIR4 * TS^2 \quad (6.16)$$

O GRÁFICO 6.14 mostra a relação entre os valores obtidos com o modelo e os valores observados. Nota-se que, com exceção do valor extremo ($Ac4=31mm$) os outros dados foram bem modelados.

GRÁFICO 6.14 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS




Em uma segunda análise foram utilizadas somente as variáveis independentes: NDVI, TS, SWIR3 e SWIR5. O melhor modelo quanto ao critério geral e critério de validação foi o obtido através da equação (6.17).

$$Ac4 = 7830.0038 * NDVI - 5031.9059 * NDVI * TS + 807.7431 * NDVI * TS^2 \quad (6.17)$$

Nota-se uma valorização da variável NDVI nesta expressão. O GRÁFICO 6.15 mostra a relação entre os valores obtidos com o modelo e os valores observados. Este modelo conseguiu melhorar os resultados obtidos em relação a análise anterior.

GRÁFICO 6.15 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS




Este comportamento reflete-se no resultado do teste K-S que é mais favorável à modelagem realizada pela equação (6.17).

6.2.4 Solos D, E, H & I

Para as análises do grupo de solos D, E, H & I foram utilizadas quatorze amostras para modelagem e seis amostras para verificação. As análises realizadas através do algoritmo GMDH apontaram como variável independente mais sensíveis à umidade a Temperatura Superficial (TS). Dentre os modelos gerados aquele que obteve um critério geral e um critério de validação mais baixos é expresso na equação (6.18). Esta expressão apresenta dificuldade em modelar os valores mais elevados de Ac4, como é o caso de 25.6mm que foi modelado como 11.14mm ou 11.00mm (GRÁFICO 6.16).

$$Ac4 = 147.09929 - 47.60152 * TS \quad (6.18)$$

GRÁFICO 6.16 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO



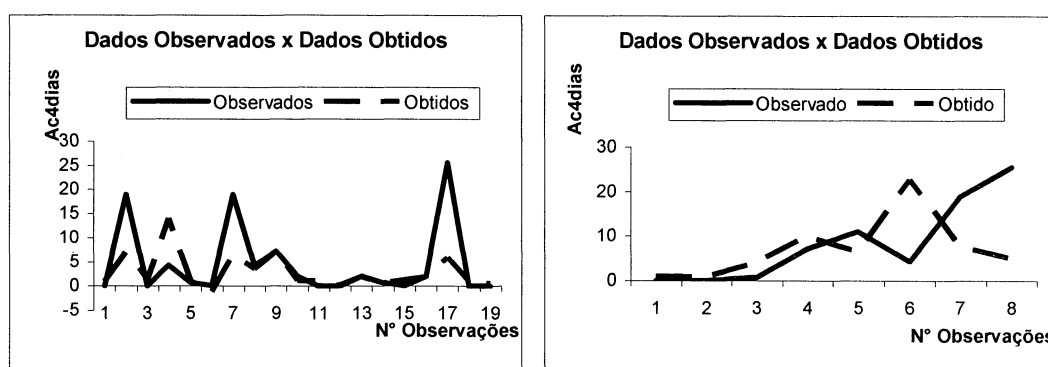
6.2.5 Todos os Tipos de Solos

Para o estudo do comportamento espectral de todos os tipos de solos através do algoritmo GMDH foram utilizadas quinze amostras para o desenvolvimento do modelo e oito amostras para sua verificação. Dentre os modelos gerados aquele que obteve um critério geral mais baixo e um critério de validação mais baixo foi o que traz como variáveis independentes NDII, SWIR6 e temperatura superficial (TS) expresso na equação (6.19).

$$Ac4 = -6.10387 * NDII^2 + 348.582 * SWIR6 - 110.0460 * SWIR6 * TS \quad (6.19)$$

O modelo sugere uma valorização das variáveis SWIR6 e TS na determinação da umidade. O GRÁFICO 6.17 mostra a relação entre os valores obtidos com o modelo e os valores observados. Como já observado em outras análises efetuadas com o algoritmo GMDH, os números mais elevados de Ac4 não são bem modelados assim tem-se, por exemplo, valores originais de 19mm modelados como 6.9mm ou 25.6mm modelados como 5.8mm.

GRÁFICO 6.17 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO




Na segunda análise utilizando o algoritmo GMDH_PNN utilizou-se como variáveis independentes somente aquelas selecionadas previamente na Análise de Regressão Múltipla: NDVI, TS, SWIR1, SWIR3 e SWIR5. Dentre os modelos gerados aquele que obteve um critério geral mais baixo foi aquele descrito pela equação (6.20).

$$Ac4 = 294.597257 * SWIR5 - 29.733852 * SWIR5 * TS^2 \quad (6.20)$$

Na equação (6.20) nota-se a importância das variáveis SWIR5 e TS na determinação da umidade.

O GRÁFICO 6.18 mostra a relação entre os valores obtidos com o modelo e os valores observados. Novamente aqui os valores mais altos de Ac4 não foram bem modelados.

GRÁFICO 6.18 – RELAÇÃO ENTRE OS VALORES OBTIDOS COM O MODELO GERADO PELO ALGORITMO GMDH E OS VALORES OBSERVADOS EM **A** VALORES MODELADOS, EM **B** VALORES PARA AVALIAÇÃO DO MODELO



6.2.6 Resultados Gerais obtidos para o ASTER através do GMDH

Através da TABELA 6.3 observa-se os dados obtidos com as modelagens geradas pelo algoritmo GMDH para as imagens ASTER. Eles indicam a presença freqüente da banda de temperatura superficial (TS) e da SWIR6 entre as variáveis independentes selecionadas pelo algoritmo.

TABELA 6.3 – DADOS REFERENTES AS MODELAGENS COM ALGORITMO GMDH, REALIZADAS COM AS IMAGENS ASTER

Solo	Algoritmo	Variáveis independentes	Variáveis selecionadas	Critério Geral	Critério Valid.
Solo B	GMDH_1	todas	SWIR6 ² , SWIR6 ² *TS SWIR6 ² *TS ²	5,46	34,10
	GMDH_2	-	-	-	-
	GMDH_1	todas	TS	3,48	8,34
Solos H & I	GMDH_2	SWIR2, SWIR4, SWIR5, TS, Tasseled	SWIR2, SWIR5*TS ²	10,74	3,39
	GMDH_1	todas	SWIR6, SWIR4*TS, SWIR6*TS, SWIR4*TS ²	6,59	0,73
Solos B, F, G	GMDH_2	NDVI, TS, SWIR3 e SWIR5	NDVI, NDVI*TS, NDVI*TS ²	7,83	4,78
	GMDH_1	todas	TS	12,53	1,19
Solos D, E, H&I	GMDH_2	-	-	-	-
	GMDH_1	todas	NDII ² , SWIR6, SWIR6*TS	2,97	9,86
Todos os Solos	GMDH_2	NDVI, TS, SWIR1, SWIR3 e SWIR5	SWIR5, SWIR5*TS ²	5,72	-

A TABELA 6.4 traz os resultados obtidos com o teste K-S para as imagens ASTER para os diferentes grupos de solos. Observa-se que em todas as modelagens os

valores de D_{\max} são inferiores ao valores de D_{critico} . Com isso em todos os casos se aceita como verdadeira a hipótese nula, de igualdade dos grupos de amostras. Porém os resultados obtidos com a correlação entre os dados obtidos com a modelagem e os dados observados não são promissores. Somente a primeira modelagem realizada com os solos H&I e a segunda, realizada com o grupo de solos B, F e G situa-se acima de 70% de correlação. As demais análises situam-se abaixo indicando baixa correlação entre os dados. Desta forma, mesmo o teste K-S ter indicado que a hipótese nula poderia ter sido aceita os dados de correlação indicam que as modelagem realizadas com o algoritmo GMDH não foram muito eficientes na determinação do acumulado de chuvas para imagens ASTER.

TABELA 6.4 – TESTES ESTATÍSTICOS: KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO

Tipo de Solo	Teste K-S		Correlação	
	D	D_{critico}	Modelo	Valid
Solo B	0.28	0.46	0,21	-
	-	-	-	-
Solo H & I	0.30	0.46	0,75	
	0.40	0.46	0,59	
Solos B, F,G	0.37	0.43	0,63	-
	0.37	0.43	0,90	-
Solos D, E, H&I	0.38	0.48	0,79	
	-	-	-	-
Todos os Solos	0.37	0.39	0,52	
	0.33	0.39	0,44	

6.3 MODIS


6.3.1 Solo B

Para a modelagem do solo B foram utilizadas treze amostras: nove amostras foram utilizadas para a modelagem e quatro para a verificação dos resultados. O modelo que obteve o melhor critério geral e de validação apresenta como variáveis independentes as bandas M3, M4, M7 através da equação (6.21).

$$Ac4 = -133.392447 * M4 + 1906.006326 * M3 * M7 \quad (6.21)$$

Esta equação evidencia a importância da banda M4 e do produto entre Banda M3 e M7 ($M3 \cdot M7$) na determinação da umidade do solo. O critério de validação é mais baixo, o que indica que as variáveis do modelo apresentam um erro grande no ajuste, porém para as variáveis de validação este erro é bem menor. A GRÁFICO 6.19 apresenta o resultado do modelo. Nota-se que os valores maiores de Ac_4 não são bem modelados.

GRÁFICO 6.19 – RESULTADOS OBTIDOS COM O ALGORITMO GMDH UTILIZANDO-SE TODAS AS VARIÁVEIS INDEPENDENTES




Em uma segunda análise utilizando o algoritmo GMDH para análise do solo B, foram utilizadas como variáveis independentes as bandas M4, M6 e a Temperatura Superficial Noturna (TSN), como sugerido pela regressão múltipla. Dentre os modelos gerados aquele que obteve um critério geral e um critério de validação mais baixos foi aquele definido pela equação (6.22).

$$Ac_4 = -139.3466 \cdot M_6 + 41177.4898 \cdot M_5^2 - 28856.3437 \cdot M_5^2 \cdot TSN \quad (6.22)$$

O critério de validação (4,74) é bem mais baixo do que o critério geral (97,72), o que indica que as variáveis do modelo apresentam um erro grande no ajuste, porém para as variáveis de validação este erro é bem menor.

O GRÁFICO 6.20 mostra a relação entre os valores obtidos com o modelo e os valores observados. Neste segundo modelo criado pelo algoritmo GMDH os valores mais altos de Ac_4 já são mais bem modelados.

GRÁFICO 6.20 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS



6.3.2 Solos H & I


Para o estudo do comportamento espectral dos solos H & I através do algoritmo GMDH foram utilizadas treze amostras: 10 para modelagem e 3 amostras para a verificação dos resultados. A análise realizada revelou como variáveis independentes a Banda M6 e a Temperatura Superficial Noturna (TSN). O que pode ser evidenciado através da equação (6.23). Nesta expressão nota-se a importância da banda 6 e da Temperatura Superficial Noturna na determinação da umidade.

$$Ac4 = 2.2098 * M6 + 413918.0523 * M6^2 - 292886.3381 * M6^2 * TSN \quad (6.23)$$

Neste modelo o critério geral obtido ainda é muito alto, porém o critério de validação (2,63) é mais baixo o que indica que as variáveis do modelo apresentam um erro grande no ajuste. Para as amostras de validação este erro é bem menor. O GRÁFICO 6.21 traz a relação entre os valores obtidos com o modelo e os valores observados.

Provou-se fazer outra análise utilizando-se o algoritmo GMDH somente com as variáveis indicadas pela regressão múltipla, porém o resultado obtido foi igual aquele onde todas as variáveis independentes entraram.

GRÁFICO 6.21 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS




6.3.3 Solos B, F & G

Para a análise dos solos B, F e G foram utilizadas doze amostras: nove para a modelagem e três para a verificação. O modelo gerado traz unicamente como variável independente a Temperatura Superficial Noturna (TSN), como mostra a equação (6.24).

$$Ac4 = 2836.337319 - 1998.307025 * TSN \quad (6.24)$$

O GRÁFICO 6.22 mostra a relação entre os valores obtidos com o modelo e os valores observados. Pelo GRÁFICO 6.22 percebe-se que uma equação contendo somente a Temperatura Superficial Noturna não consegue modelar muito bem o Acúmulo de chuva de quatro dias (Ac4), pois valores como 50.4mm e 61.9mm são nivelados (modelados como 48.7mm). Isso pode ser aceito dentro de certas necessidades onde pequenas variações do acumulado de chuva não sejam importantes.

GRÁFICO 6.22 – RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO



6.3.4 Solos D, E, H & I

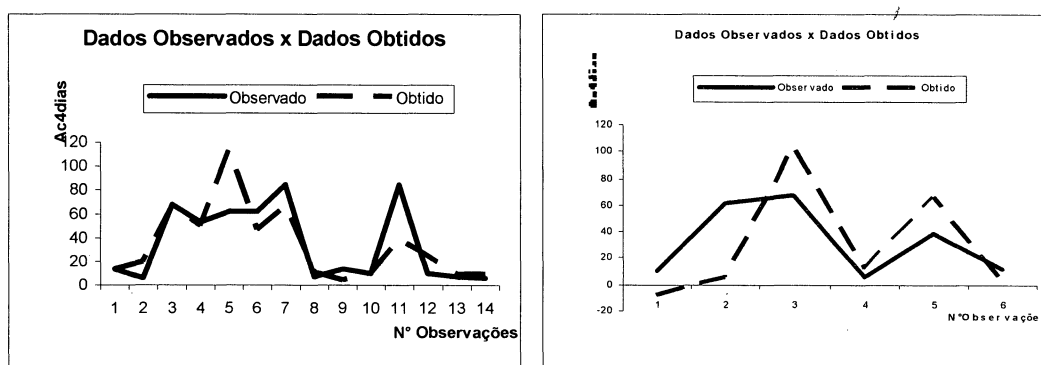
Na modelagem dos solos D, E, H & I vinte amostras foram utilizadas: 14 na modelagem e 6 amostras para verificação do modelo. Na primeira análise realizada com o algoritmo GMDH dentre os modelos gerados aquele que apresentou melhores resultados quanto ao critério geral e de validação foi o que apresentou como variáveis independentes a Banda M2, a Banda M4, a Banda M6 e Temperatura Superficial Noturna (TSN) e expresso através da equação (6.25).

$$Ac4 = -18.0057 * M4 + 147666.8785 * M2 * M6 - 104441.6503 * M2 * M6 * TSN \quad (6.25)$$

Novamente, o critério geral obtido na geração do modelo é muito alto. Já o critério de validação é mais baixo. Isto que indica que as o modelo teve dificuldades para se ajustar ao conjunto de dados, mas que o erro é bem menor quando ele é aplicado ao conjunto de validação, o que pode ser causado pelo restrito número de amostras de validação disponíveis.

O GRÁFICO 6.23 mostra a relação entre os valores obtidos com o modelo e os valores observados, onde é notado que este modelo não é muito eficiente para a modelagem do Ac4.

GRÁFICO 6.23 — RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO



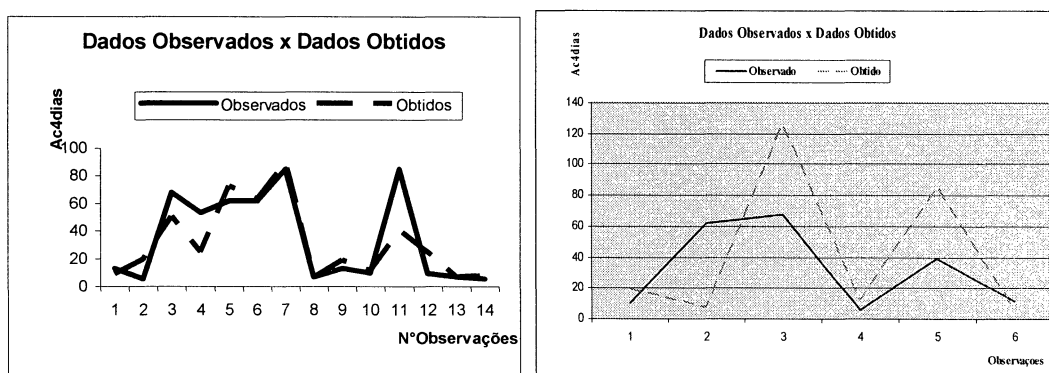
Em uma segunda análise realizada com o algoritmo GMDH foram utilizadas as variáveis independentes: Banda M1, Banda M4, Banda M6, Banda M7 e a

Temperatura Superficial Noturna (TSN), como sugerido pela Regressão Múltipla. Dentre os modelos gerados o que apresentou o critério geral mais baixo e o critério de validação mais baixo foi o expresso pela equação (6.26).

$$Ac4 = 9111082.5517 * M6 - 12902984.4800 * M6 * TSN + 4568289.7517 * M6 * TSN^2 \quad (6.26)$$

O GRÁFICO 6.24 mostra a relação entre os valores obtidos com o modelo e os valores observados. Observa-se que em relação ao primeiro modelo gerado pelo algoritmo GMDH este modelo é mais eficiente na determinação do Ac4.

GRÁFICO 6.24 — RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO




6.3.5 Modelagem com Todos os Tipos de Solos

Na modelagem de todos os tipos de solo foram utilizadas 15 amostras para a geração do modelo e 11 amostras para a sua verificação. Na primeira análise utilizando o algoritmo GMDH, o modelo selecionado, por apresentar melhores resultados quando os critérios geral e de validação, foi o que apresenta como variáveis independentes a Banda M1, a Banda M6 a Banda M7 e a Temperatura Superficial Noturna (TSN), com a seguinte equação (6.27).

$$Ac4 = 531.9844 * M6 + 1124.8001 * TSN - 1605.8043 * M1 * M7 - 811.6964 * TSN^2 \quad (6.27)$$

O GRÁFICO 6.25 mostra a relação entre os valores obtidos com o modelo e os valores observados. O resultado da modelagem pode ser considerado satisfatório muito embora na sua verificação o resultado obtido não é tão satisfatório em relação aquele obtido pela modelagem.

GRÁFICO 6.25 --- RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO




Em uma segunda análise realizada através do algoritmo GMDH, foram utilizadas como variáveis independentes as Bandas M1, M4, M5 e M6, junto com a Temperatura Superficial Noturna (TSN). Dentre os modelos gerados a partir destas variáveis aquele que obteve um critério geral e um critério de validação mais baixos foi o expresso na equação (6.28).

$$Ac4 = 26978.84999 * M6 - 19081.222 * M6 * TSN + 6.6058 * TSN^2 \quad (6.28)$$

O GRÁFICO 6.26 mostra a relação entre os valores obtidos com o modelo e os valores observados.

GRÁFICO 6.26 --- RELAÇÃO ENTRE VALORES OBTIDOS COM O MODELO E VALORES OBSERVADOS EM A VALORES MODELADOS, EM B VALORES PARA AVALIAÇÃO DO MODELO



6.3.6 Resultados Gerais obtidos para o MODIS através do GMDH

A TABELA 6.5 mostra os dados obtidos com as modelagens geradas pelo algoritmo GMDH para as imagens MODIS. Muito embora foi verificado, quase como regra geral, que nestas análises o valor do critério geral foi elevado, observa-se que o valor do critério de validação é baixo. Isto indica a modelagem foi eficiente para as amostras de verificação, mesmo com baixo desempenho durante a modelagem. Como relação às variáveis independentes selecionadas, observa-se a freqüente presença da temperatura superficial noturna (TSN) e da Banda M6 .

TABELA 6.5 – DADOS REFERENTES AS MODELAGENS COM ALGORITMO GMDH, REALIZADAS COM AS IMAGENS MODIS

Solo	Algoritmo	Variáveis independentes	Variáveis Selecionadas	Critério Geral	Crit. Valid
Solo B	GMDH_1	Todas Variáveis	M4 M3*M7	201.11	16.59
	GMDH_2	M4 M6 TSN	M6, M5 ² M5 ² *TSN	97.72	4.74
Solos H & I	GMDH_1	Todas Variáveis	M6, M6 ² , M6 ² *TSN	469.31	2.63
	GMDH_2	-	-	-	-
Solos B, F,G	GMDH_1	Todas Variáveis	TSN	12.56	6.72
	GMDH_2	-	-	-	-
Solos D, E, H&I	GMDH_1	Todas Variáveis	M4, M2*M6, M2 *M6 *TSN	415.83	2.28
	GMDH_2	M1,M4, M6, M7 TSN	M6, M6*TSN, M6*TSN ²	349.56	1.3
Todos os Solos	GMDH_1	Todas Variáveis	M6, TSN, M1*M7, TSN ²	114.57	7.81
	GMDH_2	M1, M4, M5, M6 e TSN	M6, M6*TSN,TSN ²	300.92	7.12

Quanto aos resultados obtidos com o teste K-S para as imagens MODIS (TABELA 6.6) observa-se, com exceção da segunda modelagem para o solo B, todas as demais modelagens apresentaram valores de D_{\max} bem inferiores aos de $D_{\text{crítico}}$. Considerando-se que D_{\max} é o termo estatístico utilizado para avaliar o desempenho do teste, ou seja, se $D_{\max} \geq D_{\text{crítico}}$ rejeita-se a hipótese de igualdade das amostras, então, com exceção da primeira modelagem para o solo B, todas as demais modelagens foram aceitas.

Aos se comparar o valor dos teste K-S com a correlação estatística percebe-se o mesmo comportamento, pois, com exceção da primeira modelagem todas as

demais apresentam correlação superior a 70%. Estes resultados evidenciam que a utilização do algoritmo GMDH para a modelagem de umidade do solo, através do acumulado de chuva, para imagens MODIS é eficiente.

TABELA 6.6 – TESTES ESTATÍSTICOS:KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO

Tipo de Solo	Teste K-S		Correlação	
	<i>D</i>	<i>D_{crítico}</i>	Modelo	Valid
Solo B	0.54	0.48	0.32	-
	0.23	0.48	0.73	-
Solo H & I	0.23	0.48	0.73	-
	-	-	-	-
Solos B, F,G	0.25	0.50	0.91	0.70
	-	-	-	-
Solos D, E, H&I	0.21	0.46	0.78	0.66
	0.21	0.46	0.85	0.62
Todos os Solos	0.23	0.37	0.92	0.78
	0.27	0.37	0.80	0.62

7 MODELOS BASEADOS EM REGRESSÃO MÚLTIPLA APRIMORADOS

Dando seqüência a aplicação integrada de análise multivariada na determinação da umidade do solo através do acumulado de chuva neste Capítulo são apresentados os resultados da segunda regressão múltipla aplicada a todos os tipos de solo e aos três sensores: Landsat ETM+, ASTER e MODIS.

Nesta segunda regressão múltipla as variáveis independentes foram selecionadas a partir da modelagem realizada com o algoritmo GMDH, ou seja, as variáveis selecionadas pelo algoritmo GMDH foram utilizadas em um novo modelo de regressão onde foram inclusive mantidos o grau do polinômio indicado na modelagem do GMDH. Em alguns casos esta segunda regressão foi menos eficiente do que a primeira regressão e por não representar um aperfeiçoamento do modelo não foi apresentada neste trabalho.

7.1 LANDSAT ETM+

7.1.1 Solo B

Para o solo B foram utilizadas oito amostras para modelagem para a imagem Landsat de 28 de novembro de 2002.

Nesta segunda regressão múltipla aplicada as amostras do solo B, optou-se em utilizar as mesmas variáveis independentes utilizadas na primeira regressão, porém utilizando-se a raiz quadrada da banda termal. Notou-se que com esta atitude houve uma suave melhora nos valores do R-quadrático e R-quadrático ajustado e a confiança estatística subiu de 90 para 95%. O resultado mostra o modelo de regressão múltipla que descreve a relação entre a variável dependente Ac4 e as três variáveis independentes: NDVI, TU e banda termal (TER), através da equação (7.1).

$$Ac4 = -34,252 - 52,6093 * NDVI + 58,1309 * TU + 228,117 * \sqrt{TER} \quad (7.1)$$

Estes resultados sugerem, que a inclusão da raiz quadrada da banda Termal aprimora o modelo obtido.

7.1.2 Solos H & I

Para o estudo do comportamento espectral dos solos H & I foram utilizadas dez amostras para modelagem e três amostras para a verificação dos resultados. Como o algoritmo GMDH sugeriu a utilização do produto entre NDII e a banda Termal, e a banda Termal ao quadrado procurou-se utilizar esses termos como variáveis independentes. O resultado obtido é expresso na equação (7.2).

$$Ac4 = -37,6143 + 71,951 \cdot TU + 3396,3 \cdot TER^2 - 212,571 \cdot NDII \cdot TER \quad (7.2)$$

Aqui novamente a banda termal ao quadrado apresenta um coeficiente bem mais alto que os demais termos. Ao se comparar os resultados obtidos nesta segunda regressão múltipla com a primeira regressão realizadas percebe-se que houve diminuição do R-quadrático (R^2) e do R-quadrático ajustado e um pequeno aumento do erro padrão e erro médio absoluto, indicando que na primeira regressão múltipla a modelagem obteve melhor desempenho.

7.1.3 Solos B, F & G

No estudo do comportamento espectral dos solos B, F e G através de regressão múltipla utilizando-se as variáveis obtidas através do algoritmo GMDH que são: NDII, banda Termal, o produto entre Tasseled e as duas primeiras componentes principais PC1 e PC2² observa-se que tanto o R-quadrático (R^2) como o R-quadrático ajustado são inferiores aos obtidos com a primeira regressão (52,56% e 45% respectivamente) o que caracteriza uma modelagem ruim. Desta forma optou-se em se utilizar as mesmas variáveis independentes utilizadas na regressão anterior: PC2, TU e Banda Termal (TER), porém acrescentando a banda NDII, como sugerido pelo algoritmo GMDH. A equação (7.3) obtida é descrita abaixo:

$$Ac4 = -15,4743 + 3,34608 * NDII + 90,1663 * PC2 + 39,2442 * TU + 253,062 * TER \quad (7.3)$$

Como pode ser observado na TABELA 7.1, a inclusão da variável NDII ao modelo fez com que o R-quadrático subisse de 70,8% para 73,5% e R-quadrático ajustado caísse de 59,9% para 58,4% aperfeiçoando a regressão múltipla anterior.

7.1.4 Solos D, E, H & I.

Na modelagem do grupo de solos D, E, H & I quinze amostras foram utilizadas para a geração do modelo e cinco amostras foram utilizadas para a verificação deste modelo. Ao se utilizar as variáveis obtidas através do algoritmo GMDH observa-se um resultado muito inferior ao obtido na primeira regressão. Utilizou-se em uma primeira tentativa as variáveis: NDVI, o produto entre NDVI e a componente umidade da transformação Tasseled Cap (TU), obtidas na primeira modelagem do algoritmo GMDH e posteriormente as variáveis: NDII², PC2, o produto entre NDII e PC2 e o produto entre NDII, NDVI e PC2, porém em ambos os casos tanto R-quadrático (R²) como o R-quadrático ajustado foram inferiores a 30%.

7.1.5 Todos os Tipos de Solos

Para o estudo do comportamento espectral de todos os tipos através de regressão múltipla foram utilizadas vinte e sete amostras para a modelagem e dez amostras para a verificação do modelo. Porém, ao se utilizar as variáveis obtidas com o algoritmo GMDH em uma nova regressão múltipla os resultados não foram bons. Tanto R-quadrático (R²) como o R-quadrático ajustado obtidos foram inferiores a 30% o que caracteriza uma modelagem ruim.

7.1.6 Resultados obtidos para o Landsat

Ao se analisar os dados obtidos através da regressão múltipla aplicada a imagem Landsat, utilizando como variáveis independentes aquelas sugeridas pelo

algoritmo GMDH, observa-se que para o grupo de solos D, E, H & I e para o conjunto de todos os tipos de solos não houve melhora nos resultados, pelo contrário, os resultados de uma segunda regressão mostraram-se insatisfatórios, explicando uma proporção inferior a 30% da variabilidade do acumulado de chuva, TABELA 7.1.

No caso solo B esta segunda regressão aprimorou os resultados da primeira, muito embora de forma pouco significativa. Houve ligeiro aumento do R-quadrático (R^2) e do R-quadrático ajustado e uma pequena diminuição do erro padrão e erro médio absoluto, os resultados obtidos explicam mais que 90% da variabilidade do acumulado de chuva.

Para o grupos de solo H & I, ao se compara o resultado desta segunda regressão com o resultado obtido na primeira regressão, vê-se uma pequena piora, que sugere que se mantenha a modelagem obtida na primeira regressão.

Os solos B, F e G obtiveram nesta segunda regressão um aprimoramento do R-quadrático (R^2), porém uma diminuição do R-quadrático ajustado. Desta forma, ao se analisar sob o ponto de vista destes indicadores estatísticos somente o solo B apresentou uma melhora em sua modelagem utilizando as variáveis independentes sugeridas pelo algoritmo GMDH na regressão múltipla.

TABELA 7.1 –REGRESSÕES MÚLTIPLAS N° 2, REALIZADAS COM A IMAGEM LANDSAT

Tipo de Solo	Bandas	Sig. Est (%)	R^2	R^2 AJUSTADO	ERRO PADRÃO	EMA
Solo B	NDVI, TU, √TER	95	90,31	80,63	1,92	0,99
Solos H & I	TU, TER ² NDII*TER	95	69,11	55,87	2,75	1,95
Solos B, F, G	PC2, TU, TER, NDII	95	73,57	58,47	2,77	1,55
Solos D, E, H & I	NDVI, PC1, TER	—	—	—	—	—
Todos os Solos	NDII, TU, TER	—	—	—	—	—

A TABELA 7.2 traz os resultados obtidos com o teste K-S para a imagem Landsat para os diferentes grupos de solos. Percebe-se nas três modelagens realizadas nesta segunda análise de regressão múltipla que todas apresentaram D_{\max} inferior ao $D_{\text{crítico}}$. Isso quer dizer que em todos os casos a hipótese nula (H_0) foi aceita.

Ao se comparar os valores aos obtidos para D_{\max} na primeira regressão múltipla observa-se que para o solo B e os solos H & I eles são idênticos, sugerindo que não houve melhora nem piora quanto a similaridade dos grupos de amostras, já para o grupo de solos B, F e G o D_{\max} sofreu um ligeiro aumento sugerindo menor similaridade (ou maior diferença máxima) em relação a primeira regressão múltipla. Isso também se reflete na correlação que se manteve estável para o solo B, melhorou ligeiramente para os solos H & I e reduziu-se para o grupo de solos B,F, G.

TABELA 7.2 – TESTES ESTATÍSTICOS: KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO

Tipo de Solo	Teste K-S		Correlação	
	<i>D</i>	<i>D_{crítico}</i>	<i>Modelo</i>	<i>Val.</i>
Solo B	0.25	0.43	0,86	-
Solos H & I	0.4	0.54	0,86	0,07
Solos B, F,G	0.23	0.48	0,69	0,75
Solos D, E, H&I	-	-	-	-
Todos os Solos	-	-	-	-

Esta segunda regressão múltipla enfatizou a dificuldade de modelar-se o acumulado do chuvas (Ac4) através de imagem Landsat para grupo de solos ou para um conjunto muito heterogêneo de solos.

7.2 ASTER

7.2.1 Solo B

Para o estudo do comportamento espectral do solo B foram utilizadas entre sete amostras para modelagem e devido a este pequeno não se separou amostras para a verificação dos resultados. A modelagem realizada com o algoritmo GMDH sugere a utilização de $SWIR6^2$, do produto entre $SWIR6^2$ e Temperatura Superficial (TS) e do produto entre $SWIR6^2$ e TS^2 , porém o uso destas variáveis independentes gera um modelo com alta colinearidade. Desta forma optou-se em se desenvolver um regressão múltipla para o solo B utilizando-se as mesmas variáveis da primeira regressão, porém acrescentando-se o quadrado de $SWIR6$.

O resultado pode ser observado na equação (7.4).

$$Ac4 = 263,62 - 10,9993*NDVI - 88,2215*TS + 163,886*SWIR3 - 247,416*SWIR6^2 \quad (7.4)$$

7.2.2 Solos H & I

Como o modelo gerado pelo algoritmo GMDH apresentou inicialmente só a variável temperatura superficial na sua equação, resolveu-se realizar uma segunda regressão múltipla utilizando as mesmas variáveis da primeira regressão múltipla, porém com a Temperatura Superficial ao quadrado. O modelo gerado nesta segunda regressão apresenta é descrito pela equação (7.5).

$$Ac4 = 110,585 - 49,9985*SWIR5 - 10,6011*TS^2 \quad (7.5)$$

7.2.3 Solos B, F e G

Para esta análise, foram escolhidos 4 amostras para verificação e 13 amostras para a modelagem. Através do algoritmo GMDH foram selecionadas as seguintes variáveis: SWIR6, o produto entre SWIR4 e TS, o produto entre SWIR6 e TS e o produto entre SWIR4 e TS^2 . Para não gerar um modelo colinear optou-se em acrescentar a modelagem anterior somente a variável $SWIR6*TS$. O resultado obtido é descrito na equação (7.6).

$$Ac4 = 1674,2 - 7612,95*SWIR6 - 559,454*TS + 382,45*SWIR4 + 2466,28*TS*SWIR6 \quad (7.6)$$

7.2.4 Solos D, E, H & I

Na análise do grupo de solos D, E, H & I o algoritmo GMDH enfatizou a importância da variável Temperatura Superficial (TS), porém ao se realizar uma segunda regressão enfatizando esta variável não se obteve uma melhora significativa e

optou-se por manter a modelagem sugerida pela primeira regressão.

7.2.5 Todos os Solos

Nesta modelação de todos os solos para as imagens ASTER foram utilizadas as variáveis independentes sugeridas pelo algoritmo GMDH: NDII², SWIR6 e o produto entre SWIR6 e TS. O modelo obtido é descrito pela equação (7.7).

$$Ac4=10,7361-43,1223*NDII^2 + 620,01*SWIR6-213,123*TS*SWIR6 \quad (7.7)$$

7.2.6 Resultados obtidos para o ASTER

Ao se analisar os dados obtidos através desta segunda regressão múltipla (TABELA 7.3) aplicada as imagens ASTER observa-se que para o solo B e os solos H & I não houve quase alteração dos valores obtidos para R-quadrático (R²), R-quadrático ajustado, erro padrão e erro médio absoluto. Percebe-se que houve uma pequena melhora, porém não muito significativa.

Para o grupo de solos B, F & G houve um aprimoramento do modelo com o R-quadrático (R²) passando de 93 para 98%, o R-quadrático ajustado passando de 88.6 para 96.9% e um nítido decaimento tanto do erro padrão como do erro médio absoluto, desta forma pode-se dizer que para este grupo de solos a utilização das variáveis sugeridas pelo algoritmo GMDH melhorou em muito a modelagem obtida pela regressão múltipla.

Para o grupo de solos D, E, H & I e para o grupo formado por todos os tipos de solos a primeira regressão múltipla foi mais eficiente do que esta segunda executada com as variáveis sugeridas pelo GMDH. Isso é evidente em todos os indicadores estatísticos da regressão múltipla.

Cabe ressaltar que com exceção a modelagem realizada para o conjunto formado por todos os tipos de solo, todas as demais modelagem conseguiram explicar mais de 80% da variabilidade do acumulado de chuva. O que pode ser interpretado como um bom resultado.

TABELA 7.3 –REGRESSÕES MÚLTIPLAS Nº 2, REALIZADAS COM AS IMAGENS ASTER

Tipo de Solo	Bandas	Sig. Est (%)	R ²	R ² AJUSTADO	ERRO PADRÃO	EMA
Solo B	NDVI, SWIR3, SWIR6 ² e TS	95	93,36	86,72	4,03	1,90
Solos H & I	SWIR5, TS ²	95	82,47	73,71	5,18	2,48
Solos B, F,G	SWIR4,SWIR6, TS e SWIR6*TS	95	98,99	96,96	2,17	0,80
Solos D, E, H & I	-	-	-	-	-	-
Todos os Solos	NDII ² , SWIR6, SWIR6*TS	99	67,76	60,85	3,77	2,90

Os resultados obtidos com o teste Kolmogorov_Smirnov (teste K-S), considerando a hipótese nula (H_0) a igualdade entre os valores modelados do acúmulo de quatro dias (Ac4) e os valores observados, e considerando que a máxima diferença entre as frequências acumuladas de cada população de amostras (D_{\max}) é o termo estatístico utilizado para avaliar o desempenho do teste, observa-se que em todas as modelagem a hipótese nula é aceita. A TABELA 7.4 traz os resultados obtidos com o teste K-S para as imagens ASTER para os diferentes grupos de solos.

A correlação entre os dados modelados e os observados fica acima 80% em todos os casos, o que revela uma boa modelagem dos dados. Porém ao se analisar a correlação observada com as amostras de verificação, percebe-se que principalmente na modelagem de todos os tipos de solos juntos esse valor decai para menos de 50%.

Ao se comparar os valores obtidos com o teste K-S nesta segunda regressão múltipla com os valores obtidos na primeira regressão percebe-se que o valor de D_{\max} mantém-se o mesmo para todas as modelagens realizadas com exceção daquela realizada para o grupo de solo B, F, G que apesar de apresentar uma correlação maior e melhores valores estatísticos nesta segunda regressão múltipla, apresentou um aumento do D_{\max} . Porém isto não comprometeu a aceitação da hipótese nula.

Quanto às correlações, a correlação calculada com as amostras utilizadas para a modelagem se manteve acima de 80%. Porém, a correlação calculada com as amostras de verificação aponta baixos resultados para o experimento com todos os tipos de solos.

TABELA 7.4 – TESTES KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO, IMAGENS ASTER, 2ª REGRESSÃO MÚLTIPLA

Tipo de Solo	Teste K-S		Correlação	
	<i>D</i>	<i>D_{crítico}</i>	<i>Modelo</i>	<i>Val.</i>
Solo B	0.29	0.46	0,96	-
Solos H & I	0.20	0.46	0,91	0,95
Solos B, F, G	0.33	0.43	0,97	-
Solos D, E, H & I	-	-	-	-
Todos os Solos	0.26	0.39	0,82	0,47

7.3 MODIS

Para o sensor MODIS, também foi repetida a série de modelagens usando a regressão linear múltipla, só que desta vez foram usadas as variáveis apontadas pelos melhores resultados dos modelos baseados no algoritmo GMDH. A seguir são apresentados os resultados para os diferentes grupos de solos.

7.3.1 Solo B

Para o solo B as variáveis independentes utilizadas foram as bandas M4, M5 e M6, bem como a Temperatura Superficial Noturna (TSN). A elas acrescentou-se o produto entre as Banda M3 e Banda M7, como sugerido pelo algoritmo GMDH. Doze amostras foram utilizadas nesta análise, oito foram utilizadas para a modelagem, e quatro amostras foram utilizadas na verificação, uma amostra foi retirada em relação à análise anterior. O resultado mostra o modelo de regressão múltipla que as variáveis independentes descrevem em relação a variável dependente Ac4 através da equação (7.8). Os valores dos coeficientes apontam a importância das variáveis TSN e do produto entre as Bandas M3 e M7.

$$\begin{aligned} \text{Ac4} = & 4614,0 - 1368,78 \cdot \text{M4} + 602,737 \cdot \text{M5} + 940,286 \cdot \text{M6} - 3426,29 \cdot \text{TSN} \\ & + 1258,04 \cdot \text{M3} \cdot \text{M7} \end{aligned} \quad (7.8)$$

O R-quadrático é superior ao resultado obtido na análise anterior. O R-quadrático ajustado que é mais conveniente para comparar modelos com números

diferentes de variáveis independentes também é um pouco superior ao obtido na análise anterior. O erro-padrão estimado é muito similar ao obtido na análise anterior e o erro absoluto médio (MAE), que é a média dos valores dos resíduos, é novamente aprimorado em relação a análise anterior. Pode-se então dizer que de uma forma geral a inclusão do produto entre as bandas M3 e M7 melhorou os resultados obtidos com esta análise.

7.3.2 Solos H & I

Nesta segunda regressão múltipla foram utilizadas como variáveis independentes as bandas M1, M4 e M7, bem como o quadrado da banda M6 e a Temperatura Superficial Noturna (TSN), como sugerido pelo modelo gerado pelo algoritmo GMDH. O modelo gerado é expresso através da equação (7.9).

$$Ac4 = 7175,7 - 2623,57*M4 + 5021,46*M6^2 - 667,076*M7 + 2158,41*M1 - 5086,18*TSN \quad (7.9)$$

7.3.3 Solos B, F e G

Como o modelo gerado pelo algoritmo GMDH para os solos B, F e G traz em sua equação somente a variável TS, optou-se por não se realizar uma segunda modelagem com a regressão múltipla e manter a modelagem realizada na primeira regressão.

7.3.4 Solos D, E, H e I

Nesta análise foram utilizadas como variáveis independentes a banda M6, o produto entre as bandas M1 e M7 e a Temperatura Superficial Noturna (TSN) ao quadrado (TSN^2), como sugerido pelo algoritmo GMDH. O novo modelo gerado é descrito pela equação (7.10).

$$Ac4 = 2649,55 + 483,83*M6 - 1345,41*TSN^2 - 1418,18*M1*M7 \quad (7.10)$$

7.3.5 Todos os Solos

Para modelar a umidade em todos os tipos de solos segundo a regressão múltipla de solo usando as variáveis sugeridas pelo algoritmo GMDH, foram utilizadas como variáveis independentes o produto entre as bandas M1 e M7, a banda M4, a banda M5 e a Temperatura Superficial Noturna ao quadrado (TSN²). Nesta análise foram utilizadas 21 amostras para a modelagem e 11 amostras para a verificação do modelo. O modelo gerado é expresso na equação (7.11).

$$Ac4=1242,99-47,376*M1*M7-74,5679*M4+172,478*M5-633,743*TSN^2 \quad (7.11)$$

7.3.6 Resultados obtidos para as Imagens MODIS

Ao se analisar os dados obtidos através de regressão múltipla aplicada as imagens MODIS observa-se que de quatro modelagens três apresentaram valores de R-quadrático (R²) superior a 90%, ou seja, nestes três casos os modelos gerados explicam mais do que 90% da variabilidade do acumulado de chuva de quatro dias (Ac4). Ao se referir ao R-quadrático ajustado (R² ajustado), que é mais conveniente para comparar modelos com números diferentes de variáveis independentes, percebe-se que também nestas três modelagem os valores situa-se todos acima de 80% (TABELA 7.5). A única modelagem que apresenta resultados regulares foi a realizada para todos os tipos de solo, mas mesmo assim tanto o valor de R-quadrático (R²) como o valor de R-quadrático ajustado estão acima de 70%.

Ao se comparar estes resultados com aqueles obtidos com a primeira regressão múltipla observa-se que para o solo B e os solos H & I houve uma melhora em todos os valores estatísticos da regressão múltipla, porém esta melhora foi muito sutil, por exemplo, o valor de R-quadrático (R²) passou de 93,6 para 95,2% no caso do solo B. Porém ao se comparar os resultados obtidos com o grupo de solos D, E, H & I e com todos os tipos de solos juntos percebe-se uma melhora significativa nos valores

estatísticos. No caso dos solos D, E, H & I o valor de R-quadrático (R^2) subiu de 86,3% para 95,2% o mesmo ocorre para os demais valores. Com isso percebe-se que a utilização das variáveis sugeridas pelo algoritmo GMDH melhorou muito a modelagem de grupos de solos através de imagens MODIS.

TABELA 7.5 – DADOS REFERENTES AS REGRESSÕES MÚLTIPLAS N° 2, REALIZADAS COM AS IMAGENS MODIS

Tipo de Solo	Bandas	Sig. Est (%)	R^2	R^2 AJUSTADO	ERRO PADRÃO	EMA
Solo B	M4, M5, M6, TSN, M3 x M7	95	95,28	87,41	11,03	4,86
Solos H & I	M1, M4, M6, M7 TSN	99	92,26	85,81	10,82	5,66
Solos B, F,G	M1, M2, M4, M7 TSN	—	—	—	—	—
Solos D, E, H & I	M3, M4, M5, TSN	99	95,20	92,32	8,38	4,94
Todos os Solos	M1, M4, M5, TSN	99	78,46	73,08	12,59	9,31

Quanto aos resultados obtidos com o teste K-S para as imagens MODIS observa-se que em todas as modelagens realizadas $D_{\max} < D_{\text{crítico}}$, e desta forma a hipótese nula (H_0) de similaridade entre o grupo de amostras, pode ser confirmada. Isso releva um bom resultado na modelagem dos dados, o mesmo revelado pela correlação entre os dados observados e os dados gerados (TABELA 7.6).

Ao se comparar estes resultados com os resultados obtidos pela primeira regressão, observa-se que no caso do solo B e H & I o valor de D_{\max} é igual em ambas as análises. Porém, para o grupo de solos D, E, H & I e para todos os tipos de solos em conjunto, embora os resultados estatísticos da segunda regressão múltipla sejam mais promissores que os da primeira regressão, os valores de D_{\max} obtidos são um pouco superiores na segunda regressão, isso indicaria um pior desempenho no segundo caso. O mesmo diagnóstico é observado com o resultado da correlação.

TABELA 7.6 – TESTES ESTATÍSTICOS:KOLMOGOROV-SMIRNOV (K-S) E CORRELAÇÃO

Tipo de Solo	Teste K-S		Correlação	
	D	$D_{\text{crítico}}$	Modelo	Val.
Solo B	0.23	0.48	0,82	-
Solos H & I	0.23	0.48	0,90	-
Solos B, F,G	-	-	-	-
Solos D, E, H&I	0.36	0.46	0,89	0,65
Todos os Solos	0.27	0.37	0,86	0,86

8 MODELAGEM USANDO A ANÁLISE DISCRIMINANTE

A Análise Discriminante foi utilizada para categorizar o acumulado de chuva em grupos. A intenção, diferentemente das outras análises, foi tentar se criar um modelo por categorias, assim os dados disponíveis foram utilizados para compor as características espectrais de cada categoria. Isso foi feito em relação ao acumulado de chuva.

Em todos os casos, como nas outras análises multivariadas realizadas anteriormente, a variável dependente foi o acumulado de chuva de quatro dias (Ac4). A diferença é que na análise discriminante a variável dependente aparece categorizada. Isso, em um processo classificatório como é o caso da análise discriminante, ajuda na geração de um mapa ou carta gerado por categorias e em caso de predição a partir das equações classificatórias e discriminantes.

Para a imagem Landsat e para as imagens ASTER, a variável dependente foi categorizada em classes organizadas de acordo com a TABELA 8.1, em função da variação dos dados disponíveis.

TABELA 8.1 – CATEGORIAS DE ACUMULADO DE CHUVA PARA A IMAGEM LANDSAT E ASTER.

Ac4	Categoria
Valores entre 0mm e 9,9mm	0
Valores entre 10mm e 19,9mm	10
Valores entre 20mm e 29,9mm	20
Valores entre 30mm e 39,9mm	30

Para as imagens MODIS como os dados de acumulado de chuva foram mais amplos foram acrescentadas outras classes como pode ser observado na TABELA 8.2.

TABELA 8.2 – CATEGORIAS DE ACUMULADO DE CHUVA PARA A IMAGEM MODIS.

Ac4	Categoria
Valores entre 0mm e 9,9mm	0
Valores entre 10mm e 19,9mm	10
Valores entre 20mm e 29,9mm	20
Valores entre 30mm e 39,9mm	30
Valores entre 50mm e 59,9mm	50
Valores entre 60mm e 69,9mm	60
Valores entre 80mm e 89,9mm	80

Nas Análises Discriminantes foram utilizadas todas as variáveis independentes relacionadas a cada sensor.

8.1 LANDSAT

Para a imagem Landsat um total de vinte e oito amostras foram utilizadas para a modelagem e dez amostras foram utilizadas para testar o modelo. Somente dois grupos (0mm e 10mm) foram discriminados porque os dados disponíveis para esta imagem não permitiram que outros grupos fosse discriminados.

Uma função discriminante explicando 100% dos resultados foi obtida, apresentando uma confiança estatística de 99%. Foram discriminados dois grupos *a priori* representando as categorias de acúmulo de chuva e foram construídas duas funções classificatórias para estes grupos (TABELA 8.3), uma para cada grupo de acúmulo de chuva. Estas funções são utilizadas para predizer a que categoria uma nova observação irá pertencer.

TABELA 8.3 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4, LANDSAT

	0mm	10mm
NDII	51,388	47,144
NDVI	-64,486	-72,060
PC1	-199,751	-220,402
PC2	584,573	671,041
Tasseled	326,161	363,296
Termal	10246,900	10697,200
Constante	-595,858	-645,670

A função discriminante obtida e expressa na equação (8.1) é utilizada para discriminar entre os dois grupos de (Ac4). A partir da magnitude relativa dos coeficientes da equação (8.1) pode-se determinar como as variáveis independentes são utilizadas para discriminar entre os grupos de Ac4.

$$\begin{aligned}
 \text{Ac4} = & 0,2688 \cdot \text{NDII} + 0,5612 \cdot \text{NDVI} + 0,8160 \cdot \text{PC1} - 0,6314 \cdot \text{PC2} - \\
 & 1,0763 \cdot \text{TU} - 0,711 \cdot \text{TER}
 \end{aligned}
 \tag{8.1}$$

Este modelo obteve 92,8% de acerto na classificação das amostras utilizadas na modelagem, no caso das amostras utilizadas para a verificação do modelo este acerto foi de apenas 50%.

Uma nova análise foi realizada utilizando somente as variáveis independentes: NDII, Tasseled Cap–umidade e banda Termal conforme indicou a primeira regressão múltipla. Neste caso a função discriminante também explicou 100% da variabilidade do acumulado de chuva (Ac4) com uma confiança estatística de 95%. Foram geradas duas funções classificatórias para os dois grupos de Ac4 (0mm e 10mm) cujos coeficientes são apresentados na TABELA 8.4.

TABELA 8.4 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4, LANDSAT

	0mm	10mm
NDII	1,440	-8,684
Tasseled	96,200	109,091
Termal	7830,150	7983,590
Constante	-478,314	-496,893

A função discriminante obtida é expressa pela equação (8.2).

$$Ac4 = 0,961464*NDII - 0,560132*TU - 0,363131*TER \quad (8.2)$$

Este novo modelo obteve 89,3% de acerto na classificação das amostras utilizadas na modelagem, e no caso das amostras utilizadas para a verificação do modelo este acerto foi de 70%. Em ambos modelos para as amostras de verificação os valores de 10mm foram modelados em 0mm.

8.2 ASTER

Para o estudo do comportamento espectral das imagens ASTER, vinte amostras foram utilizadas para a modelagem através de Análise Discriminante e oito foram utilizadas para a verificação do modelo.

Foram discriminados quatro grupos *a priori* representado as categorias de acúmulo de chuva (0mm,10mm, 20mm e 30mm) e foram construídas quatro funções

classificadoras, uma para cada grupo (TABELA 8.5). Estas funções são utilizadas para prever a que categoria uma nova observação irá pertencer.

TABELA 8.5 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4 - ASTER

	0mm	10mm	20mm	30mm
NDII	-1583,37	-1442,98	-1498,86	-1404,69
NDVI	2188,61	1972,45	2016,94	1927,91
TS	2261,41	2060,74	2076,32	2099,32
SWIR1	-4190,75	-3753,91	-3724,56	-3749,11
SWIR2	-7772,39	-7930,28	-9102,07	-5821,36
SWIR3	8837,40	8315,08	7409,89	8752,38
SWIR4	38313,30	35003,30	37065,50	34481,00
SWIR5	-35972,00	-32532,50	-32927,20	-34149,70
SWIR6	2342,54	2245,13	2454,13	1920,03
Tasseled	568,14	578,38	502,87	535,09
Constante	-4284,05	-3537,37	-3593,13	-3668,15

Posteriormente, a função discriminante, expressa na equação (8.3), foi gerada para discriminar entre os diferentes níveis de valores de Ac4. O modelo gerado apresenta confiança estatística de 95%, e explica 89,53% da variabilidade dos valores de Ac4.

$$\begin{aligned}
 Ac4 = & 2,12912*NDII - 4,20796*NDVI - 1,772*TS + 5,14987*SWIR1 - \\
 & 0,200824*SWIR2 - 6,88867*SWIR3 - 29,1629*SWIR4 + \\
 & 29,1695*SWIR5 - 1,29261*SWIR6 - 0,220512*TU
 \end{aligned} \quad (8.3)$$

A classificação realizada utilizando as amostras para modelagem apresentou um acerto de 100%, porém no caso das amostras utilizadas para a verificação este acerto decaiu para 50%.

Uma nova análise discriminante foi realizada desta vez utilizando como variáveis independentes NDVI, TS, SWIR1, SWIR3, SWIR4 e SWIR5. Entre elas somente SWIR4 não foi indicada pela regressão múltipla e sim pelos altos coeficientes que apresentou na equação discriminante anterior. A primeira função discriminante obtida com esta nova modelagem explica 95,6% da variabilidade do Ac4.

Quatro equações classificatórias foram geradas para discriminar entre os

quatro níveis distintos de Ac4. Os coeficientes obtidos para as funções classificatórias são apresentados na TABELA 8.6.

TABELA 8.6 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4, ASTER

	0mm	10mm	20mm	30mm
NDVI	548,834	480,737	468,031	471,733
TS	1640,12	1501,1	1507,21	1537,07
SWIR1	-4618,28	-4205,72	-4048,34	-4198,56
SWIR3	20108,7	18432,9	17935,6	18852,0
SWIR4	16033,0	14682,7	15133,7	15286,7
SWIR5	-31559,6	-28985,7	-29121,4	-30076,4
Constante	-2824,02	-2352,47	-2371,54	-2463,82

A função discriminante obtida é dada pela equação (8.4).

$$Ac4 = 1,8908*NDVI + 1,5969*TS - 6,9095*SWIR1 + 23,5846*SWIR3 + 14,5549*SWIR4 - 29,2843*SWIR5 \quad (8.4)$$

Este modelo apresentou 100% de acerto na classificação das amostras utilizadas para a modelagem e somente 35% de acerto na classificação das amostras utilizadas para a verificação do modelo.

8.3 MODIS

Para a caracterização espectral do acúmulo de chuva através da Análise Discriminante de imagens MODIS, vinte três amostras foram utilizadas para a modelagem e onze amostras foram utilizadas para a verificação do modelo.

Sete grupos foram discriminados conforme a TABELA 8.7, que apresenta os coeficientes que formam as funções classificatórias para cada um desses grupos. Foram determinadas seis funções discriminantes e nenhuma delas apresentou confiança estatística de 90%, a primeira função discriminante explica somente 69,28% dos resultados e é descrita na equação (8.5).

TABELA 8.7 - COEFICIENTES QUE FORMAM AS FUNÇÕES CLASSIFICATÓRIAS PARA CADA CATEGORIA DE AC4, MODIS

	0mm	10mm	20mm	30mm	50mm	60mm	80mm
M1	-1636,24	-1669,92	-1920,12	-1609,65	-1604,75	-1180,36	-1245,03
M2	402,325	396,415	404,133	322,85	347,067	357,957	386,349
M3	-11716,9	-11762,8	-11466,4	-11909,5	-11718,4	-11614,2	-11764,4
M4	16104,9	16219,7	16109,8	16273,0	16051,6	15463,8	15711,0
M5	-5111,78	-5155,69	-5084,02	-4976,06	-4968,85	-4839,43	-4958,22
M6	7561,75	7705,02	7363,83	7410,54	7414,49	7370,47	7486,44
M7	-9455,73	-9619,34	-9149,32	-9327,58	-9319,7	-9344,8	-9430,0
TSN	74521,2	74830,1	73918,4	73973,9	73956,9	73731,7	73957,0
CONSTANTE	-52601,0	-53043,0	-51748,4	-51838,3	-51813,7	-51517,4	-51829,0

$$Ac4 = -12,321*M1 + 1,27087*M2 - 3,1882*M3 + 18,3299*M4 - 5,4938*M5 + 4,4057*M6 - 3,2537*M7 + 0,9915*TSN \quad (8.5)$$

Nesta modelagem 71,91% dos casos foram classificados corretamente no caso das amostras utilizadas para a modelagem e houve 45,4% de acerto na classificação das amostras utilizadas para a verificação do modelo.

Duas outras análises foram realizadas utilizando somente as variáveis sugeridas pela regressão múltipla. No primeiro caso foram utilizadas as variáveis independentes: bandas 1, 4 e 5, bem como a Temperatura Superficial Noturna (TSN) neste caso a função discriminante obtida explicava 86% da variabilidade do acumulado de chuva e gerou 60,8% de acerto na classificação das amostras que elaboraram o modelo. Em uma outra análise foram utilizadas como variáveis independentes as bandas M1, M7, M6 e a temperatura superficial noturna (TSN). Neste caso a função discriminante obtida explicou 77% da variabilidade do acumulado de chuva e gerou um acerto de 65% na classificação das amostras utilizadas na modelagem. Por considerar estes resultados insuficientes optou-se por não se considerar estas últimas modelagens.

9 ANÁLISE E DISCUSSÃO DOS RESULTADOS OBTIDOS

Os Capítulos 5, 6, 7 e 8 apresentam os resultados obtidos com as análises multivariadas realizadas. O escopo deste capítulo é o de avaliar os resultados obtidos e analisá-los dentro do contexto da resposta espectral que eles representam concomitantemente realizar a discussão destes resultados a luz de trabalhos já realizados e do estado da arte no assunto.

Para realizar tal análise serão utilizados dois princípios: o primeiro uma análise baseada nos resultados estatísticos obtidos e segundo uma avaliação a partir do que estes resultados representam em termos espectrais. Desta forma os quatro primeiros subitens (9.1 a 9.4) deste capítulo trazem uma avaliação feita estritamente sobre o ponto de vista estatístico, deixando para a seção 9.5 a análise sob a ótica dos resultados espectrais da modelagem.

9.1 ANÁLISE DOS RESULTADOS LANDSAT ETM+

Para a determinação do melhor resultado obtido para o satélite Landsat procurou-se analisar os resultados dos parâmetros estatísticos obtidos em cada análise e posteriormente o resultado obtido através do teste Kolmogorov-Smirnov (K-S) e da correlação entre dados observados e dados obtidos com o modelo.

Ao se analisar os dados obtidos através das regressões múltiplas aplicadas a imagem Landsat, observa-se que para o solo B a primeira regressão realizada pode ser considerada satisfatória, pois apresenta o valor de R-quadrático (R^2) elevado, explicando mais que 90% da variabilidade do acumulado de chuva. Para os demais grupos de solo este valor decai abaixo de 70% e no caso da modelagem de todos os tipos de solo juntos este valor não atinge nem 50%. Ao se referir ao R-quadrático ajustado (R^2 ajustado), que é mais conveniente para comparar modelos com números diferentes de variáveis independentes percebe-se o mesmo comportamento.

O erro-padrão estimado, que mostra o desvio padrão do resíduo, e o erro

médio absoluto (EMA), que é a media dos valores dos resíduos, também são menores para o solo B que para os demais tipos de solo (TABELA 9.1).

TABELA 9.1 – RESULTADOS OBTIDOS ATRAVÉS DAS REGRESSÕES MÚLTIPLAS PARA A MODELAGEM DO AC4 PARA A IMAGEM LANDSAT.

Tipos de Solos	R ²	R ²	R ² AJUSTADO	R ² AJUSTADO	ERRO PADRÃO	ERRO PADRÃO	EMA	EMA
Solo B	90,10	90,31	80,20	80,63	1,94	1,92	1,01	0,99
Solo H & I	75,94	69,11	61,50	55,87	2,80	2,75	1,83	1,95
Solos B, F,G	70,88	73,57	59,96	58,47	2,72	2,77	1,74	1,55
Solos D, E, H&I	62,15	—	50,80	—	3,22	—	2,12	—
Todos os Solos	44,12	—	36,83	—	3,73	—	2,76	—

Ao se comparar os resultados obtidos com a segunda regressão múltipla percebe-se que a melhora obtida foi muito pequena, no caso do solo B. Houve uma pequena elevação dos valores de R-quadrático (R^2) e R-quadrático ajustado. Para os demais grupos de solos a segunda regressão múltipla não representou um aprimoramento do modelo.

A modelagem realizada através do algoritmo GMDH enfatizou a importância da variável banda Termal (TER) ao quadrado na determinação da umidade do solo. Para a determinação da umidade do solo para a imagem Landsat notou-se que o algoritmo GMDH não conseguiu uma boa modelagem para os valores de acumulado de chuva (Ac4) mais elevados, desta forma, salvo a modelagem realizada para o solo B e para o grupos de solos B, F e G, nos demais casos percebeu-se uma quase homogeneização dos valores obtidos e a não modelação dos valores mais elevados do acumulado de chuva.

O teste Kolmogorov_Smirnov (teste K-S), aplicado para o estudo da igualdade estatística de duas populações, considerou neste estudo a hipótese nula (H_0) sendo a igualdade entre os valores de Ac4 modelados e os valores observados.

O teste K-S foi aplicado em todas as modelagens geradas para a imagem Landsat para os diferentes grupos de solos (TABELA 9.2). Os resultados indicam que no caso do solo B o desempenho de todas as modelagens foi similar e neste caso o valor de D obtido é sempre inferior ao valor de $D_{\text{crítico}}$, o que indica que a hipótese nula

pode ser aceita.

TABELA 9.2 – RESULTADOS OBTIDOS COM O TESTE K-S PARA A IMAGEM LANDSAT

Tipo de Solo	RM1	GMDH1	GMDH2	RM2	$D_{crítico}$
	D	D	D	D	
Solo B	0.25	0.25	0.25	0.25	0.43
Solos H & I	0.40	0.20	0.50	0.40	0.54
Solos B, F,G	0.15	0.31	0.31	0.23	0.48
Solos D, E, H&I	0.47	0.27	0.45	-	0.44
Todos os Solos	0.37	0.22	0.48	-	0.33

Para o grupo de solos B, F e G o valor mais baixo de D foi obtido com a primeira regressão múltipla, fato comprovado pelo valor de correlação obtido para esta modelagem (TABELA 9.3).

As modelagens realizadas para o grupo de solos D, E, H & I e para todos os tipos de solos a hipótese nula é rejeitada, com exceção daquela gerada pelo algoritmo GMDH. Este resultado coincide com aquele apresentado pela correlação entre os dados de acumulado de chuva modelados e os dados observados.

A TABELA 9.3 traz o resultado da correlação os dados observados e os dados gerados pela modelagem, bem como a correlação entre os dados observados e as amostras utilizadas para a verificação do modelo. Observa-se que somente as modelagens realizadas para o solo B e para os solos H & I através de regressão múltipla apresentam correlação superior a 80%. Para o grupo de solos B, F e G esta correlação fica entorno de 60% a 75% e para os demais grupos inferior a 65%.

TABELA 9.3 – RESULTADOS OBTIDOS COM A CORRELAÇÃO ENTRE OS DADOS OBSERVADOS E AQUELES GERADOS PELO MODELO (M) E ENTRE OS DADOS OBSERVADOS E AS AMOSTRAS UTILIZADAS PARA A VERIFICAÇÃO DO MODELO (V)

Tipo de Solo	RM1		GMDH1		GMDH2		RM2	
	M	V	M	V	M	V	M	V
Solo B	0,86	-	0,59	-	0,89	-	0,86	-
Solos H & I	0,85	0,07	0,67	-	0,78	-	0,86	0,07
Solos B, F,G	0,74	0,89	0,64	0,60	0,62	0,60	0,69	0,75
Solos D, E, H&I	0,65	0,42	0,19	0,40	-0,36	-0,35	-	-
Todos os Solos	0,66	0,45	0,36	-0,06	0,43	0,24	-	-

Com base nos resultados apresentados pode-se dizer que para o solo B, com exceção da primeira modelagem realizada pelo algoritmo GMDH todas as demais

apresentam valores são superiores a 80% de correlação e podem ser, portanto utilizadas para a predição do acumulado de chuva para este tipo de solo através da imagem Landsat. O modelo que obteve maior correlação entre o acumulado de chuva gerado e o observado foi aquele obtido através da segunda modelagem gerada pelo algoritmo GMDH e expressa na equação (9.1).

$$Ac4s = -9.25907 + 174.960967 * TU * TER + 1213.240506 * TER^2 \quad (9.1)$$

Para os solos H & I o melhor resultado na modelagem do Ac4 foi aquele obtido com a regressão múltipla expressão na equação (9.2).

$$Ac4 = -37,6143 + 71,951 * TU + 3396,3 * TER^2 - 212,571 * NDII * TER \quad (9.2)$$

E para os solos B, F e G o melhor resultado foi obtido através da regressão múltipla que modelou o acumulado de chuva através da expressão (9.3).

$$Ac4 = -17,0897 + 77,3078 * PC2 + 37,3439 * TU + 258,77 * TER \quad (9.3)$$

Para os demais grupos de solos a modelagem realizada através de regressão múltipla ou através do algoritmo GMDH não se mostrou eficiente no caso da imagem Landsat. Desta forma pode-se dizer os resultados obtidos sugerem que o Landsat não é muito eficiente na modelagem de respostas espectrais heterogêneas, como é o caso de uma modelagem que una vários tipos de solos.

Pode-se dizer também que a modelagem da umidade do solo, através de regressão múltipla e o algoritmo GMDH foram as que se mostraram mais eficientes, muito embora os resultados alcançados não sejam muito satisfatórios. Percebe-se uma constante presença das variáveis: Tasseled Cap – umidade (TU) e banda Termal (TER) ao quadrado nas equações modeladoras da umidade. Há dificuldade na modelagem dos valores mais elevados do acumulado de chuva, o que indica que para a imagem a modelagem ideal não é linear.

A partir dos dados apresentados pode-se concluir que através da imagem Landsat somente a modelagem realizada para o solo B pode ser considerada

satisfatória, sendo a modelagem realizada para o grupo de solos H & I e B, F e G pode ser considerada regular e as modelagens realizadas para os grupos D, E, H & I e todos os solos juntos podem ser consideradas impróprias.

9.2 ANÁLISES DOS RESULTADOS_ ASTER

Ao se analisar os dados obtidos através da regressão múltipla aplicada as imagens ASTER observa-se que na primeira regressão múltipla, em todos os casos, o valor de R-quadrático (R^2) é superior a 80%, ou seja, todos os modelos gerados explicam mais do que 80% da variabilidade do acumulado de chuva (Ac4). Ao se referir ao R-quadrático ajustado (R^2 ajustado), percebe-se que somente a modelagem realizada para os solos H & I situa-se abaixo de 80% e mesmo assim atinge 73%.

O erro-padrão estimado, que mostra o desvio padrão do resíduo, e o erro médio absoluto (EMA), que é a média dos valores dos resíduos, também são menores na modelagem dos solos D, E, H & I, o que coincide com os melhores resultados obtidos para o R-quadrático e R-quadrático ajustado (TABELA 9.4).

TABELA 9.4 – RESULTADOS OBTIDOS ATRAVÉS DAS REGRESSÕES MÚLTIPLAS PARA A MODELAGEM DO AC4 PARA AS IMAGENS ASTER.

Tipos de Solos	R^2	R^2	R^2	R^2	ERRO	ERRO	EMA	EMA
			AJUSTADO	AJUSTADO	PADRÃO	PADRÃO		
Solo B	93,17	93,36	86,33	86,72	4,08	4,03	2,12	1,90
Solo H & I	82,4	82,47	73,60	73,71	5,19	5,18	2,48	2,48
Solos B, F,G	93,5	98,99	88,6	96,96	4,07	2,17	2,44	0,80
Solos D, E, H&I	97,15	-	95,11	-	2,02	-	1,40	-
Todos os Solos	88,9	67,76	84,7	60,85	3,03	3,77	1,97	2,90

Ao se comparar estes dados com os dados obtidos com a segunda regressão múltipla percebe-se que somente para o grupo de solos B, F e G há uma melhora em todos os índices estatísticos, ou seja, o R-quadrático (R^2) sobe de 93 para 98,9%, o R-quadrático ajustado sobe de 88,6% para 96,9% e há um decaimento tanto nos valores do erro-padrão como no erro médio absoluto. Isso indica que neste caso o acréscimo da variável SWIR6*TS melhorou o modelo.

As análises realizadas com o algoritmo GMDH indicam que os valores mais

elevados do acumulado de chuva (Ac4) não foram bem modelados (CAPÍTULO 6), muito embora os valores obtidos para o critério geral tenham sido baixos.

No teste Kolmogorov-Smirnov (K-S) aplicado a todas as modelagens geradas pelo algoritmo GMDH, os valores de D_{\max} são inferiores ao valores de $D_{\text{crítico}}$. Com isso, em todos os casos se aceita como verdadeira a hipótese nula, de igualdade dos grupos de amostras. Para os resultados do teste Kolmogorov_Smirnov (teste K-S) aplicado às modelagens geradas pela regressão múltipla, observa-se novamente que em todas as modelagem a hipótese nula é aceita. Considerando que o valor mais baixo para D é o que indica melhor ajuste dos dados, observa-se que com exceção do solo B, cujo valor mais baixo de D corresponde a análise GMDH_1, os demais valores de D são mais baixos nas modelagens realizadas pela primeira regressão múltipla (TABELA 9.5).

TABELA 9.5 – RESULTADOS OBTIDOS COM O TESTE K-S APLICADO PARA AS IMAGENS ASTER

Tipo de Solo	RM1	GMDH1	GMDH2	RM2	$D_{\text{crítico}}$
	D	D	D	D	
Solo B	0.29	0.28	-	0.29	0.46
Solos H & I	0.29	0.30	0.40	0.20	0.46
Solos B, F,G	0.22	0.37	0.37	0.33	0.43
Solos D, E, H&I	0.31	0.38	-	-	0.48
Todos os Solos	0.26	0.37	0.33	0.26	0.39

Se, por outro lado são analisados os resultados obtidos com a correlação dos dados modelados e os dados observados, observa-se que, com exceção do grupo de solos B,F, G as correlações de todas as modelagens são mais altas nas análises de regressão múltipla 1 e são todas superiores a 90% o que revela uma boa modelagem dos dados.

Porém, ao se analisar a correlação observada com as amostras utilizadas para a verificação do modelo percebemos que principalmente na modelagem de todos os tipos de solos juntos e do grupo de solos D, E, H & I esse valor decai para cerca de 50% (TABELA 9.6).

TABELA 9.6 – RESULTADOS OBTIDOS COM A CORRELAÇÃO ENTRE OS DADOS OBSERVADOS E AQUELES GERADOS PELO MODELO (M) E ENTRE OS DADOS OBSERVADOS E AS AMOSTRAS UTILIZADAS PARA A VERIFICAÇÃO DO MODELO (V)

Tipo de Solo	RM1		GMDH1		GMDH2		RM2	
	M	V	M	V	M	V	M	V
Solo B	0,96	-	0,21	-	-	-	0,96	-
Solos H & I	0,91	0,95	0,75	-	0,59	-	0,91	0,95
Solos B, F,G	0,96	-	0,63	-	0,90	-	0,97	-
Solos D, E, H&I	0,99	0,58	0,79	-	-	-	-	-
Todos os Solos	0,94	0,52	0,52	-	0,44	-	0,82	0,47

No caso das modelagens realizadas com o algoritmo GMDH os resultados obtidos com a correlação entre os dados obtidos com a modelagem e os dados observados não são promissores. Somente a primeira modelagem realizada com os solos H&I e a segunda, realizada com o grupo de solos B, F e G situa-se acima de 70% de correlação. As demais análises situam-se abaixo indicando baixa correlação entre os dados. Desta forma, mesmo o teste K-S ter indicado que a hipótese nula poderia ter sido aceita na modelagem gerada pelo GMDH, os dados de correlação indicam que estas modelagens não foram muito eficientes na determinação do acumulado de chuvas para imagens ASTER.

Com base nestes resultados pode-se dizer que para o solo B a modelagem mais eficiente foi aquela realizada através da primeira regressão múltipla e que tem na equação (9.4) a sua expressão.

$$Ac4 = 312,545 - 26,9384*NDVI + 244,258*SWIR3 - 257,875*SWIR6 - 94,083*TS \quad (9.4)$$

Nesta equação observa-se um equilíbrio entre as variáveis independentes com uma leve valorização das variáveis SWIR3 e SWIR6.

Também para os solos H&I a análise de regressão múltipla foi mais eficiente na determinação do acumulado de chuva, modelado através da equação (9.5).

$$Ac4 = 204,64 - 63,2057*TS - 50,254*SWIR5 \quad (9.5)$$

Na determinação do acumulado de chuva através de imagens ASTER para o

grupo de solos B, F e G com exceção da primeira modelagem realizada com o algoritmo GMDH todas as demais se mostraram muito eficientes, porém dentre elas a que obteve o melhor desempenho foi a regressão múltipla realizada a partir das variáveis independentes sugeridas pelo algoritmo GMDH. Esta modelagem é expressa através da equação (9.6).

$$Ac4 = 1674,2 - 7612,95*SWIR6 - 559,454*TS + 382,45*SWIR4 + 2466,28*TS*SWIR6 \quad (9.6)$$

Na modelagem do acumulado de chuva para o grupo de solos D, E, H e I o melhor resultado também foi obtido através da regressão múltipla. Neste caso observa-se que o resultado obtido com os dados modelados foi muito mais eficiente do que quando aplicada aos dados utilizados para a verificação do modelo. A equação que expressa a melhor modelagem para este grupo de solos é dada pela equação (9.7). Pelos valores dos coeficientes apresentados nesta equação nota-se a importância da variável SWIR2 e SWIR5 na determinação da umidade.

$$Ac4 = 237,718 - 37,771*NDII - 55,098*TS - 906,937*SWIR2 + 537,218*SWIR5 - 40,959*TS \quad (9.7)$$

Para a modelagem de todos os tipos de solo conjuntamente o melhor resultado também foi obtido através da regressão múltipla expressa na equação (9.8). Nesta equação nota-se a importância das variáveis SWIR3 e SWIR5 para a modelagem.

$$Ac4 = 189,053 - 31,685*NDVI - 53,693*TS + 167,318*SWIR1 - 619,194*SWIR3 + 414,63*SWIR5 \quad (9.8)$$

Os dados obtidos com as imagens ASTER revelam êxito nas modelagens realizadas através de regressão múltipla, muito embora o resultado de algumas verificações não tenham sido ótimos, eles refletem a heterogeneidade espectral que estes grupos apresentam. Percebe-se que no caso das imagens ASTER o algoritmo

GMDH não se mostrou tão eficiente quanto a modelagem realizada a partir da regressão múltipla. Estes resultados são bem mais promissores do que aqueles obtidos para a imagem Landsat, pois os índices estatísticos tais como R-quadrático, R-quadrático ajustado são bem mais elevados nas análises de regressão efetuadas com os dados ASTER. E os valores obtidos com o teste K-S também são baixos evidenciando uma confirmação da hipótese nula.

Nas equações geradas observa-se a presença constante da Temperatura Superficial (TS) em todas as análises realizadas e bem como um predomínio da banda SWIR5. O índice NDVI e as bandas SWIR3 e SWIR6 são presentes eventualmente, sendo que a modelagem realizada para todos os tipos de solo pode ser considerada eficiente uma vez que tanto o R-quadrático quanto o R-quadrático ajustado apresentam valores que explicam mais de 80% da variabilidade do acumulado de Ac4.

9.3 ANÁLISE DOS RESULTADOS MODIS

Ao se analisar os dados obtidos através de regressão múltipla aplicada as imagens MODIS observa-se em todos os casos que o valor de R-quadrático (R^2) é superior a 80%, ou seja, todos os modelos gerados explicam mais do que 80% da variabilidade do acumulado de chuva (Ac4). Ao se referir ao R-quadrático ajustado (R^2 ajustado), se percebe que somente a modelagem realizada para os todos os tipos de solos juntos situa-se abaixo de 80% e mesmo assim atinge 70% (TABELA 9.7).

TABELA 9.7 – RESULTADOS OBTIDOS ATRAVÉS DAS REGRESSÕES MÚLTIPLAS PARA A MODELAGEM DO AC4 PARA AS IMAGENS MODIS

Tipos de Solos	R^2	R^2	R^2 AJUSTADO	R^2 AJUSTADO	ERRO PADRÃO	ERRO PADRÃO	EMA	EMA
Solo B	93,69	95,28	87,34	87,41	11,04	11,03	5,8	4,86
Solo H & I	91,47	92,26	84,35	85,81	11,37	10,82	5,96	5,66
Solos B, F,G	96,17	-	92,96	-	5,42	-	2,81	-
Solos D, E, H&I	86,38	95,20	80,32	92,32	12,71	8,38	8,72	4,94
Todos os Solos	75,75	78,46	70,04	73,08	13,23	12,59	9,5	9,31

O erro-padrão estimado, que mostra o desvio padrão dos resíduos, e o erro médio absoluto (EMA), que é a média dos valores dos resíduos, também são mais

elevados se comparados às análises realizadas com as imagens Landsat e ASTER mais isso pode ser reflexo da maior variabilidade dos dados encontrada nestas imagens.

Ao se comparar os resultados obtidos com a segunda regressão múltipla, realizada a partir dos resultados obtidos com o algoritmo GMDH, observa-se que em todas as modelagens houve melhora, porém discreta. Com exceção da modelagem realizada para o grupo de solos D, E, H e I, cujos valores de R-quadrático (R^2) e R-quadrático ajustado melhoraram significativamente com a segunda regressão múltipla (TABELA 9.7).

Quanto aos resultados obtidos com o algoritmo GMDH nota-se que, quase como regra, nestas análises o valor do critério geral foi elevado. Observa-se, porém, que o valor do critério de validação é baixo, o que indica que para as amostras de verificação a modelagem foi eficiente. Estes resultados evidenciam que a utilização do algoritmo GMDH para a modelagem de umidade do solo, através do acumulado de chuva, para imagens MODIS é eficiente.

Ao se analisar os resultados obtidos com o teste Komolgorov-Smirnov (K-S) para as imagens MODIS observa-se que em todos os casos os valores obtidos para o D_{max} são inferiores aos valores do $D_{critico}$.

Ao se comparar os resultados do teste K-S para o algoritmo GMDH observa-se que os valores de D são similares aos valores obtidos pela regressão múltipla, com exceção a modelagem gerada pelo GMDH para o solo B que apresentou um resultado ruim na primeira aplicação do algoritmo GMDH (TABELA 9.8).

TABELA 9.8 – RESULTADOS OBTIDOS COM O TESTE K-S PARA AS IMAGENS ASTER

Tipo de Solo	RM1	GMDH1	GMDH2	RM2	$D_{critico}$
	D	D	D	D	
Solo B	0.23	0.54	0.23	0.23	0.48
Solos H & I	0.23	0.23	-	0.23	0.48
Solos B, F,G	0.17	0.25	-	-	0.50
Solos D, E, H&I	0.27	0.21	0.21	0.36	0.46
Todos os Solos	0.23	0.23	0.27	0.27	0.37

Esses resultados também são confirmados pelos dados de correlação entre os valores modelados e os valores observados.

A correlação dos dados obtidos com a modelagem e os dados observados são todos acima de 80%, o que revela uma boa modelagem dos dados. E ao se analisar a correção observada com as amostras utilizadas para a verificação do modelo percebe-se que principalmente na modelagem de todos os tipos de solos juntos e do grupo de solos D, E, H & I esse valor é igual ou acima de 80% (TABELA 9.9).

TABELA 9.9 – RESULTADOS OBTIDOS COM A CORRELAÇÃO ENTRE OS DADOS OBSERVADOS E AQUELES GERADOS PELO MODELO (M) E ENTRE OS DADOS OBSERVADOS E AS AMOSTRAS UTILIZADAS PARA A VERIFICAÇÃO DO MODELO (V)

Tipo de Solo	RM1		GMDH1		GMDH2		RM2	
	M	V	M	V	M	V	M	V
Solo B	0,80	–	0,32	–	0,73	–	0,82	–
Solos H & I	0,90	–	0,73	–	–	–	0,90	–
Solos B, F,G	0,98	0,20	0,91	0,70	–	–	–	–
Solos D, E, H&I	0,92	0,80	0,78	0,66	0,85	0,62	0,89	0,65
Todos os Solos	0,87	0,85	0,92	0,78	0,80	0,62	0,86	0,86

Desta forma pode-se dizer que a modelagem do acumulado de chuva através de imagens MODIS, para o tipo de solo B, obteve bom resultado tanto nas regressões múltiplas como na modelagem através do algoritmo GMDH onde foram utilizadas as variáveis independentes sugeridas pela primeira regressão múltipla. O melhor resultado foi obtido, porém através da segunda regressão múltipla e expresso através da equação (9.9).

$$Ac4 = 4614,0 - 1368,78*M4 + 602,737*M5 + 940,2986*M6 - 3426,29*TSN + 1258,04*M3*M7 \quad (9.9)$$

O caso dos solos H & I é muito similar ao do solo B, pois todas as análises realizadas apresentaram resultados igualmente satisfatórios podendo-se sugerir como o melhor modelo aquele expresso pelas equações (9.10) ou (9.11) gerados a partir das regressões múltiplas.

$$Ac4 = 9046,97 - 2490,4*M4 + 1081,22*M6 - 964,221*M7 + 2373,12*M1 - 6447,38*TSN \quad (9.10)$$

Esta equação valoriza as variáveis TSN, M1 e M4 na determinação da umidade.

$$Ac4 = 7175,7 - 2623,57*M4 + 5021,46*M6^2 - 667,076*M7 + 2158,41*M1 - 5086,18*TSN \quad (9.11)$$

Como a diferença entre estas duas equações é somente o uso da M6 ao quadrado considera-se que um modelo simplificado é preferido a um modelo mais complexo na busca da predição de uma variável. Desta forma a opção da equação (9.10) parece ser a mais indicada na predição de Ac4.

Para o grupo de solos B, F e G observa-se que a melhor modelagem do acumulado de chuva de 4 dias foi obtida através da primeira regressão múltipla (equação 9.12), porém quando da aplicação do modelo nas amostras selecionadas para a verificação o melhor resultado foi obtido através da modelagem gerada pelo algoritmo GMDH (equação 9.13), onde somente a variável TSN aparece.

$$Ac4 = 2459,9 - 2398,4*M1 - 474,379*M2 + 2128,86*M4 + 938,806*M7 - 1689,54*TSN \quad (9.12)$$

$$Ac4 = 2836.337319 - 1998.307025*TSN \quad (9.13)$$

Ao se analisar os resultados obtidos para o grupo de solos D, E, H e I vê-se que a melhor modelagem foi aquela obtida a partir da primeira regressão múltipla, muito embora novamente neste caso os resultados obtidos com as outras modelagens são igualmente satisfatórios. A equação (9.14) descreve o modelo obtido.

$$Ac4 = 6128,18 - 685,78*M3 + 667,187*M4 + 197,896*M5 - 4395,41*TSN \quad (9.14)$$

Finalmente, a modelagem que melhor prevê o acumulado de chuva para todos os tipos de solos através de imagens MODIS é aquela gerada pelo algoritmo GMDH (9.15).

$$\begin{aligned} \text{Ac4} = & 531.9844 * \text{M6} + 1124.8001 * \text{TSN} - 1605.8043 * \text{M1} * \text{M7} - \\ & 811.6964 * \text{TSN}^2 \end{aligned} \quad (9.15)$$

Observa-se que, diferentemente do que foi observado para as imagens ASTER, para as imagens MODIS tanto o algoritmo GMDH (neste caso para a modelagem dos solos B, F, e G e para todos os tipos de solo conjuntamente) como a regressão múltipla conseguiram modelar a variabilidade do acumulado de chuva.

Estes resultados são mais promissores do que aqueles obtidos para a imagem Landsat, porém inferiores aos obtidos com as imagens ASTER. Os índices estatísticos - R-quadrático, R-quadrático ajustado - são bons, explicando entre 70 a 90% das variações do acumulado de chuva. Os valores D, do teste K-S, também são baixos evidenciando uma confirmação da hipótese nula.

Um dos problemas evidenciados é a dificuldade em se modelar alguns dos valores mais elevados do Ac4, principalmente através do algoritmo GMDH, limitado até um polinômio de 3º grau.

Em todas as equações geradas observa-se a presença da Temperatura Superficial Noturna (TSN) e um predomínio das bandas M4 e M7. Eventualmente estão presentes as bandas M1 e M6.

Percebe-se que para o satélite MODIS o modelo que mais indicado à determinação da umidade corresponde a um polinômio de 2º grau, diferentemente do que foi observado para o satélite ASTER.

9.4 RESULTADOS DAS ANÁLISES DISCRIMINANTES

Enquanto nas análises de regressão e na aplicação do algoritmo GMDH utilizou-se os dados pontuais do acumulado de chuva na Análise Discriminante utilizou-se “classes” de acumulado de chuva. O resultado é desta forma diferente daquele esperado pelas análises anteriores porque irá fornecer não a predição de um dado de Ac4, mas a predição de uma classe.

Como abordado no CAPÍTULO 8, referente a Análise Discriminante, o

acumulado de chuva (Ac4) foi subdividido em classes correspondentes a 10mm. Os resultados mostram que para o Landsat o modelo que utilizou as variáveis independentes NDII, TU e TER obteve 89,3% de acerto na classificação das amostras utilizadas na modelagem, e 70% de acerto para as amostras utilizadas para a verificação do modelo. Para as imagens ASTER este acerto foi de 100% na classificação realizada utilizando as amostras para modelagem, porém no caso das amostras utilizadas para a verificação este acerto decaiu para 50%. E para as imagens MODIS a modelagem obteve 71,91% dos casos classificados corretamente e apenas 45,4% de acerto na classificação das amostras utilizadas para a verificação do modelo.

Como se observa, com exceção da imagem Landsat, que obteve um resultado intermediários, os demais sensores obtiveram resultados não satisfatórios. Isso pode ser entendido por dois motivos: o primeiro é a variabilidade dos dados que no caso da imagem Landsat foi baixa, pois apresentava somente duas classes de Ac4. Outro motivo é a divisão das classes que poderia ter sido feita de forma mais ampla ou através de categorias como baixa, média e alta pluviosidade o que com certeza aprimoraria os resultados obtidos.

9.5 DISCUSSÃO - RESULTADOS ESPECTRAIS

Como mencionado anteriormente há a necessidade de se desenvolver métodos simplificados para caracterizar as propriedades do solo em áreas extensas e de se obter dados em áreas onde medições *in situ* não são possíveis e nem caracterizam uma grande variação espaço-temporal.

Pensando na necessidade de métodos simplificados é que devemos buscar analisar os resultados obtidos. A obtenção de modelos milaborantes não é a intenção deste trabalho que visa, porém, dentro do possível, otimizar as informações que podem ser obtidas em diferentes sensores (Landsat, ASTER e MODIS) e dentro de suas características de resolução espacial e temporal indicar qual o melhor modelo na caracterização da umidade do solo através de um método indireto.

Sabe-se também que a umidade do solo como parâmetro físico não pode ser obtida diretamente de dados de Sensoriamento Remoto, por isso faz-se necessário uma modelagem que revele qual combinação de bandas e índices é ótima para a obtenção deste parâmetro.

Neste trabalho procurou-se utilizar dados de acumulado de chuva para calibrar o modelo, não fazendo uso, portanto de outros dados auxiliares de campo. Trata-se de uma modelagem restritamente voltada ao comportamento espectral da superfície.

Os resultados obtidos foram avaliados de acordo com o tipo de solo e com cada sensor. Observa-se que para o satélite Landsat, o solo B foi modelado através do produto entre a banda termal e o índice Tasseled Cap-umidade, além da banda termal ao quadrado. Com os solos H & I, cujo comportamento pedológico difere-se do solo B, principalmente no que se refere à profundidade do solo, textura e disponibilidade de oxigênio, o resultado apresentou também o índice NDII em sua equação.

Pode-se dizer que no caso do solo B a profundidade do solo é menor, a textura mais grossa e há uma boa disponibilidade de oxigênio, o que indica que não há tendência de retenção da água. Já nos solos H & I estas características são opostas indicando solos mais profundos, com textura predominantemente fina e variável disposição de oxigênio. São solos mais heterogêneos e com maior tendência à retenção de água. Esta diferença de características pedológicas pode se refletir no acréscimo do índice NDII no modelo dos solos H & I. É interessante notar que o resultado obtido com o satélite Landsat, para a modelagem de todos os tipos de solos simultaneamente, ou seja, para uma situação de grande diversidade de características pedológicas, o modelo obtido foi similar ao obtido para os solos H e I, com a presença dos índices NDII, Tasseled Cap – umidade e banda termal ao quadrado. Como era de se esperar o modelo baseia-se em índices que enfatizam o infravermelho próximo e médio.

A tendência de valorização do infravermelho próximo e médio é nítida em todos os três sensores analisados. Isso fica mais evidente no Satélite ASTER, cuja resolução espectral do infravermelho é mais ampla.

A modelagem gerada para o satélite ASTER indica que para uma caracterização geral da umidade do solo o infravermelho próximo principalmente entre 2.185 – 2.225 μ m (SWIR3), 2.295 – 2.365 μ m (SWIR5) e 2.360 – 2.430 μ m (SWIR6) foram os comprimentos mais eficientes.

O satélite MODIS também mostra esta tendência com a valorização das bandas M4, M6 e M7 na modelagem da umidade para todos os tipos de solo.

Uma outra constante nos resultados obtidos foi a presença da banda termal e, caso do dos satélites ASTER e MODIS, da temperatura de superfície.

Alguns estudos sugerem que pelo menos em condições de superfícies bem úmidas a relação entre a temperatura de superfície e NDVI é mais diretamente relacionada a umidade superficial do solo através do aumento da inércia termal do solo, devido a umidade (FRIEDL e DAVIS, 1994).

Na determinação da umidade, uma dificuldade freqüente foi a modelagem dos valores mais elevados do acumulado de chuva. Isso ocorreu principalmente com o satélite Landsat e pode ser considerado um indício de que a modelagem ideal, neste caso, não é linear. No caso do satélite ASTER a modelagem linear mostrou-se mais eficiente.

Esta diferenciação no tipo de modelagem também pode estar associada ao fato do ASTER possuir uma resolução espectral melhor no infravermelho o que faz com que uma modelagem linear, que envolva diferentes bandas, possa ser eficiente na detecção da umidade.

Ao se analisar os resultados obtidos com o satélite MODIS e especialmente com o satélite ASTER vemos que a utilização das imagens que correspondem a reflectância superficial foi muito útil na modelagem.

Segundo WEIDONG *et al.* (2002) para todos os comprimentos de onda e para todos os tipos de solo os resultados mostram que para quantidades baixas de umidade do solo, a reflectância decai quando a umidade do solo aumenta, e inversamente depois de um ponto critico, a reflectância aumenta com o aumento da umidade do solo. No caso deste estudo, como se trata de uma região com tendência ao predomínio do

clima seco, principalmente no período entre maio e outubro, a tendência é que a reflectância decaia quando a umidade do solo aumente.

Quanto ao tipo de análise que pode ser considerado mais eficiente na determinação da umidade sabe-se que a análise regressões lineares múltiplas, na modelagem de atributos do solo, tem sido alvo de vários estudos. Neste estudo mostrou-se eficiente as regressões lineares múltiplas aplicadas as imagens ASTER, porém sua combinação com os resultados do algoritmo GMDH mostrou-se mais eficiente quando se tratando das imagens MODIS.

No caso do Landsat, cuja resposta espectral não aparenta ser linear ou pelo menos não corresponde a uma modelagem polinomial simples, a performance do algoritmo GMDH mostrou-se mais eficiente, porém evidenciou-se que para imagens Landsat não se pode modelar uma variedade grande de solos simultaneamente. O algoritmo GMDH vem sendo aplicado em estudos de predição onde se dispõe de poucas informações e quando não se conhece a relação das variáveis independentes com a variável dependente.

Um comportamento misto onde tanto um análise linear como a utilização do algoritmo GMDH atuaram de forma similar foi observado para o satélite MODIS. Neste sensor a performance de ambas análises se mostrou eficiente.

Desta forma pode-se concluir que a utilização de imagens ASTER, especialmente da reflectância da superfície no comprimento de onda do infravermelho próximo, e da temperatura superficial integradas em um polinômio simples é o método mais eficiente na previsão da umidade do solo sendo que as imagens MODIS embora apresentem resultados um pouco inferiores também podem ser utilizadas com sucesso na determinação da umidade do solo.

9.6 ANÁLISE DOS RESULTADOS VOLTADA AO ESTUDO DE MOVIMENTOS DE MASSA

Quando se escolheu trabalhar com a detecção da umidade do solo em uma região montanhosa, como a região de Campania, um dos motivos foi sua contribuição ao estudo de movimentos de massa, mais especificamente deslizamentos de terra, comuns nesta região.

Como mencionado anteriormente, o índice de acumulado de chuva dos últimos três dias é um índice pluviométrico utilizado pela Secretaria do Meio Ambiente do Estado de São Paulo e pela defesa Civil do Estado de São Paulo para a determinação dos índices de "atenção", "alerta" e "alerta máximo" a escorregamentos na região litorânea. A análise de alguns episódios de chuvas que provocaram escorregamentos no litoral de São Paulo permitiu estabelecer que valores de chuvas acumulados em 3 dias indicam que acima de 100mm para a Baixada Litorânea e 120 mm para o litoral norte de São Paulo haveria alta possibilidade de ocorrência de escorregamento.

A região de Campania é alvo freqüente de deslizamentos de terra, porém, suas características climáticas, geomorfológicas e geológicas são muito distintas da região litorânea do estado de São Paulo e desta forma seria um erro muito grosseiro utilizar limite de 100mm como o indicativo de risco a escorregamento.

Nesta região, para que ocorra movimentos de massa a concentração de água no solo pode ser muito inferior àquelas esperadas para o clima tropical. Para se determinar o valor crítico do acumulado de chuva, que neste estudo foi utilizado o acumulado de 4 dias (Ac_4), por apresentar melhores valores de correlação individual entre os valores de chuva e os valores das bandas/índices. Este valor crítico de Ac_4 , porém, deve ser estimado através de estudos específicos ao longo de alguns anos e sua associação a deslizamentos.

Uma hipótese que pode ser utilizada são valores próximos a 80mm para as regiões mais íngremes e considerando a tipologia de solos da região. Utilizando este

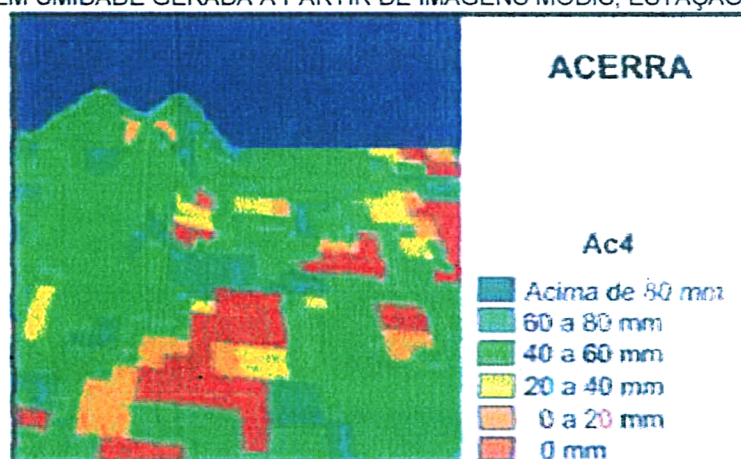
valor e as equações genéricas (elaboradas para todos os tipos de solo), tanto das imagens ASTER como MODIS, pode-se mapear as áreas consideradas como críticas a escorregamentos.

Como exemplo tem-se as imagens umidade geradas para a região da estação pluviométrica de Acerra.

Para gerar a imagem umidade, com 1km de resolução espacial, foi utilizada a imagem MODIS de 06 de abril de 2003, e a equação (9.15). Esta imagem umidade indica a quantidade de umidade (em mm) distribuída espacialmente na área. Após aplicar a equação 9.15 a imagem resultante foi classificada em categorias de acordo com o valor de Ac_4 . Desta forma, foram obtidas categorias cujos valores de Ac_4 são 0mm (em vermelho), correspondentes, portanto, a baixa umidade e categorias de alta umidade, ou seja, valores de Ac_4 acima de 80mm (em verde escuro), FIGURA 9.1.

Como os valores acima de 80mm representam alta umidade, os locais indicados pela imagem umidade com estes valores, representariam, portanto, áreas com maior probabilidade de ocorrer deslizamento de terra (quando associadas a declividade alta e média).

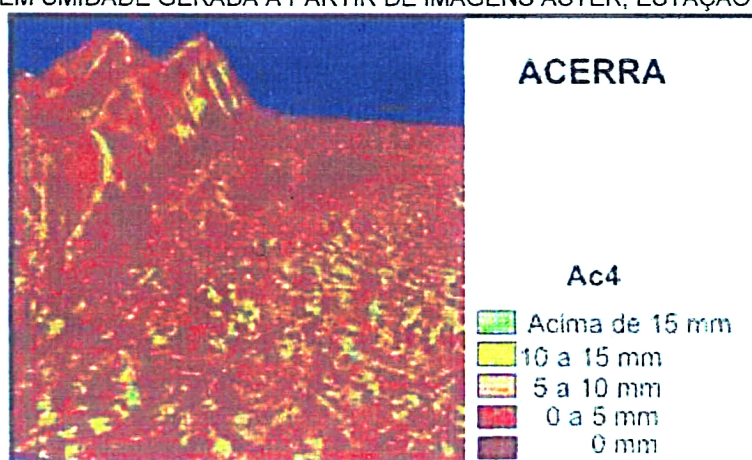
FIGURA 9.1 – IMAGEM UMIDADE GERADA A PARTIR DE IMAGENS MODIS, ESTAÇÃO DE ACERRA, EM 3D.



A imagem umidade para a estação de Acerra também foi gerada utilizando a imagem ASTER de 21 de junho de 2000 e a equação (9.8). O resultado é apresentado na FIGURA 9.2.

Como esta imagem foi gerada a partir da imagem de 21 de junho de 2000, que representa o período mais seco do ano, tem-se somente a representação do acumulado de chuva (Ac_4) inferior a 20mm. Assim são indicados valores de Ac_4 de 0mm (em vermelho escuro) e os valores superiores a 15mm, porém inferiores a 20mm em verde. Como se tratar de uma imagem gerada a partir do processamento de imagens ASTER, a resolução espacial é de 30m. Neste caso não há áreas com risco a deslizamentos de terra.

FIGURA 9.2 – IMAGEM UMIDADE GERADA A PARTIR DE IMAGENS ASTER, ESTAÇÃO DE ACERRA, EM 3D.



10 CONCLUSÕES E RECOMENDAÇÕES

10.1 CONCLUSÕES

O objetivo principal deste estudo foi o de modelar a umidade do solo e sua distribuição espacial a partir da análise multitemporal de imagens multiespectrais em escala de semidetalhe e regional, utilizando imagens de diferentes sensores como Landsat ETM, ASTER e MODIS

Para se avaliar o comportamento dos modelos em áreas heterogêneas do ponto de vista pedológico e geomorfológico, isolando-se a influência da vegetação, a área escolhida foi uma região montanhosa, com grande variabilidade de tipos de solos, e com baixa densidade de vegetação.

Na tentativa de aprimorar os dados espectrais foram gerados índices, tais como Índices de Vegetação NDVI e NDII, Transformação Tasseled Cap e Análise dos Componentes Principais das Bandas do Infravermelho próximo.

Além disso, buscou-se utilizar três tipos distintos de análises multivariadas para gerar os modelos: Regressão Múltipla, Algoritmo GMDH, a combinação destes dois métodos e Análise Discriminante, para se obter a modelagem. Utilizou-se, em muitos casos, um número limitado de amostras.

Diante deste quadro e com os resultados obtidos com as análises conclui-se que:

- Os resultados obtidos demonstram que é possível modelar a umidade do solo e sua distribuição espacial a partir da análise multitemporal de imagens multiespectrais em escala de semidetalhe e regional.
- Em todos os três sistemas Landsat ETM, ASTER e MODIS há uma tendência de valorização do dos comprimentos de onda do infravermelho próximo e médio, principalmente das imagens termais ou de temperatura superficial.

- A modelagem realizada com as imagens Landsat ETM, foi eficiente somente para um tipo de solo, analisado isoladamente, o solo B, que apresentou em seu modelo as variáveis: banda termal, o índice Tasseled Cap- umidade, além da banda termal ao quadrado. Para os solos H & I, cujo comportamento pedológico difere-se do solo B, no que se refere à profundidade do solo, textura e disponibilidade de oxigênio, o resultado incluiu também o índice NDII. O Landsat ETM não apresentou resultados satisfatórios para outros tipos de solo, não podendo ser considerado eficiente na modelagem de um grupo heterogêneo de solos, não sendo, portanto, recomendado para elaboração de um modelo genérico de controle da umidade do solo.
- A modelagem realizada com imagens ASTER indica como o comprimento mais eficiente o infravermelho, principalmente entre $2.185 - 2.225\mu\text{m}$ (SWIR3), $2.295 - 2.365\mu\text{m}$ (SWIR5) e $2.360 - 2.430\mu\text{m}$ (SWIR6). Os melhores modelos foram gerados através da regressão múltipla. As imagens ASTER mostraram-se eficientes na geração de um modelo genérico, que envolva diversos tipos de solo, na detecção da umidade. Este modelo incluiria as bandas SWIR1, SWIR3, SWIR5, temperatura superficial e o índice NDVI.
- A modelagem realizada com imagens MODIS também mostra uma tendência de valorização das bandas do infravermelho, principalmente nos comprimentos M4, M6 e M7. As análises mais eficientes na elaboração do modelo foram tanto as regressões múltiplas como o algoritmo GMDH. Na geração de um modelo genérico para o estudo da umidade do solo as variáveis presentes foram: banda M6, Temperatura Superficial Noturna ao quadrado e o produto entre as bandas M1 e M7. O modelo gerado apresenta um polinômio de segundo grau.

- Conclui-se que ambas imagens, ASTER e MODIS, são eficientes na determinação da umidade do solo independentemente das variações texturais e composicionais dos solos e podem ser, portanto, utilizadas em modelos genéricos de umidade. As imagens ASTER podem ser empregadas quando há necessidade de maior resolução espacial e as imagens MODIS quando o fator mais importante for a resolução temporal.
- Para estudos da umidade do solo, em escala de semidetalhe, que não necessitem de alta resolução temporal recomenda-se utilizar um sistema com imagens ASTER, que apresenta resolução espacial de 30m, e devido a sua alta resolução espectral no infravermelho permite combinar em um polinômio simples as bandas SWIR1, SWIR3, SWIR5, temperatura superficial e o índice NDVI, que fornecem um modelo eficiente na detecção da umidade.
- Em estudos dinâmicos e regionais, como para o monitoramento regional de deslizamentos de terra, recomenda-se utilizar um sistema com imagens MODIS, combinando em um polinômio de segundo grau as bandas M1, M6, M7 e a Temperatura Superficial Noturna, pois sua resolução temporal diária e resolução espacial de 1km permite a obtenção de produtos dinâmicos em escala regional.
- Quanto ao tipo de análise mais eficiente percebe-se que a regressão múltipla foi aquela que apresentou os melhores resultados, principalmente quando tratando-se de dados das imagens ASTER.
- No caso das imagens MODIS a utilização do algoritmo GMDH foi mais eficiente na obtenção da equação genérica de detecção da umidade do solo.
- Esse resultado pode refletir que os dados obtidos com as imagens

ASTER apresentam uma relação linear enquanto que os obtidos pelas imagens MODIS necessitam de um polinômio mais complexo para sua elaboração. Isso também pode ser consequência da melhor resolução espectral que as imagens ASTER apresentam em relação a outros sensores, pois, quanto mais delimitado o comprimento de onda, mais eficiente a detecção da umidade e maior a possibilidade de criar-se um modelo linear.

- Quanto ao uso da Análise Discriminante, percebe-se que somente quando da existência de um número muito grande de amostras este método pode ser bem utilizado, pois somente assim é possível criar-se equações de classificação eficientes.
- Este estudo mostrou-se eficiente em regiões parcialmente cobertas por vegetação ou com solo exposto sendo recomendado que em regiões densamente vegetadas seja estudado a influência da vegetação no parâmetro umidade.

10.2 RECOMENDAÇÕES

Este estudo demonstrou a viabilidade da utilização das imagens ASTER e MODIS na determinação da umidade do solo. Inúmeros pontos, porém podem ser desenvolvidos com maior profundidade e não o foram por necessidade de conclusão desta pesquisa, fica, porém a recomendação para futuras investidas.

- Recomenda-se que se avalie a possibilidade de se desenvolver um sistema on-line utilizando composição de imagens MODIS, segundo o modelo aqui proposto, isto poderia ser útil na detecção regional de área de risco a escorregamentos.
- Recomenda-se fazer uma aplicação similar voltada ao estudo da escassez de água, isso teria ampla aplicação na agricultura.

- Recomenda-se que se estude a influência da vegetação neste contexto, verificando se mesmo em regiões com vegetação densa, se este método pode ser aplicado.
- E por fim, recomenda-se que seja feito estudo específico para determinar qual valor de Ac_4 pode ser considerado crítico a deslizamentos de terra, para a região de Campania.

REFERÊNCIAS BIBLIOGRÁFICAS

- CHANG, D. H.; ISLAM, S. 2000. Estimation of Soil Physical Properties Using Remote Sensing and Artificial Neural Network. **Remote Sensing of Environment**, v.74, p. 534-544.
- CHAVEZ, P. S. 1996. Image - based atmospheric corrections. Revisited and improved. **Photogrammetric Engineering and Remote Sensing**, v.62, p.1025-1036.
- CHUVIECO, E. 1990. **Fundamentos de Teledetección Espacial**. 1.ed. Madrid: Ediciones Rialp, 452p.
- CHUVIECO, E.; RIANO, D.; ÁGUADO, I.; COCENO, D. 2002a. Estimation of fuel moisture content from multitemporal analysis of Landsat Thematic Mapper reflectance data: application in fire danger assessment. **Int. J.Remote. Sensing**, v.23, n.11, p.2145 –2162.
- CHUVIECO, E.; MARTIN, M. P.; PALACIOS. 2002b. Assessment of different spectral índices in the red-near-infrared spectral domain for burned land discrimination. **Int. J. Remote Sensing**, v.23, n.23, p.5103-5110.
- CRIST, E.; CICONE, R. C. 1984. Application of the Tasseled Cap Concept to Simulated Thematic Mapper Data. **Photogrammetric Engineering and Remote Sensing**, v. 50, n.3, p. 343-352.
- CRIST, E. 1985. A TM tasseled cap equivalent transformation for reflectance factor data. **Remote Sensing of Environment**, v. 17, p. 301-306.
- DI GENNARO, A. 2002. **I sistemi di terre della Campania**. Carta 1:250.000 e Legenda. Napoli: RISORSA e Regione Campania, 63p.
- DOBSON, M.C.; ULABY, F.T.; HALLIKAINEN, M.T.; EL-RAYES, M.A. 1985. Microwaves dielectric behavior of wet soil – Part II: Dielectric mixing models, **IEEE Transactions on Geoscience and Remote Sensing**, vol.23, n.1, p.35-46.
- DUBOIS, P. C. ENGMANN, J Z. 1995. Measuring soil moisture with imaging radar. **IEEE Remote Sensing**, v. 33, n.4, p. 915 – 926.
- ENGMAN, E. T. 1991. Applications of microwaves remote sensing of Soil Moisture for Water Resources and Agriculture. **Remote Sensing of Environment**, v.35, p. 213-226.
- FLASSE, S. P.; CECCATO, P. 1996. A contextual algorithm for AVHRR fire detection. **International Journal of Remote Sensing**, n.17, p.419-424.
- FIORIO, P. C.; DEMATTE, J. A. M.; NANNI, M. R.; GENU, A. M. 2003. Regressões Lineares Múltiplas utilizando-se dados espectrais obtidos por sensores em laboratório e orbital na estimativa de atributos do solo. **Anais XI SBSR**, Belo Horizonte, p. 85-92.

- FRIEDL, M.A.; DAVIS, F.W. 1994. Sources of variation in radiometric surface temperature over a tallgrass prairie. **Remote Sensing of Environment**, v. 48, 1-17.
- GAO, B. C. 1996. NDWI. A Normalized Difference Water Index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v.58. p. 257-266.
- GILLESPIE, A.R.; ROKUGAWA,S.; HOOK, S.J.; MATSUNAGA, T.; KAHLE, A.B. 1999. Temperature Emissivity Separation Algorithm Theoretical Basis Document. Version 2.4, 64 p.
- GOBRON, N.; PINTY, B.; VERSTRAETE, M.; GOVAERTS, Y. 1999. The MERIS Global Vegetation Index (MGVI): description and preliminary application. **Int. J.Remote Sensing**, v.20, n.9, p.1917-1927.
- GOBRON, N.; PINTY, B.; VERSTRAETE, M.; WIDLowski, J. L. 2000. Advanced Vegetation Indices Optimized for up-Coming Sensors: Design, Performance and A Applications. **IEEE Trans. Geos. Remote Sensing**, v.38, n.6.
- GOETZ, S.J.1997. Multisensor analysis of NDVI, surface temperature and biophysical variables at a mixed grassland site. **International Journal of Remote Sensing**, n.18 , v. 1, p.71-94.
- HEJMANOWSKA, B.; MULARZ. 2000. Integration of Multitemporal ERS2.SAR and LANDSAT TM data for Soil Moisture Assessment. **Int.Photogrammetry and Remote Sensing, Amsterdam**, v.33, part B7, p. 511-518. 1 CD-ROM.
- HILL, J., MEHL, W. 1995. Improved forest mapping by combining corrections of atmospheric and topographic effects in Landsat TM imagery. **Sensors, and Environment Applications of Remote Sensing**, 1995, Askne ed., Rotterdam, p.143 – 151.
- HOFFER, R.M. 1978. Biological and physical considerations in applying computer-aided analysis Techniques to remote sensing data. In: SWAIN, P., DAVIS, S. **Remote Sensing : the quantitative approach**. Mc.Graw- Hill, 1978.
- HOUSER, P. R. 1996. **Remote Sensing Soil Moisture using four-dimensional data assimilation**. Arizona, E.U.A., 1996. 371f. Tese de Doutorado - Universidade do Arizona.
- HUNT, E. R.; ROCK, B. N. 1989. Detection of changes in leaf water content using near and middle-infrared reflectances. **Remote Sensing of Environment**, v.30, p.43-54.
- HUANG, C.;YANG, L.; HOMER, C. W. B.; VOGELMAN, J.; DE FELICE, T. 2001. AT-Satellite reflectance: a first order normalizaton of Landsat 7 ETM+ images.USGS.
- HUANG, C.; WYLIE, B.; YANG, L.; HOMER, C.; ZYLSTRA, G. 2002. Derivation of a Tasseled Cap transformation based on Landsat 7 at-satellite reflectance. **Int. J.Remote Sensing**, v. 23, n.8, p.1741-1748.

- IRISH, R. R. 2000. Landsat 7 science data user's handbook, Report 430-15-01-003-0, National Aeronautics and Space Administration, <http://ftpwww.gsfc.nasa.gov/IAS/handbook/handbook_toc.html>
- JUSTICE, C. O.; GIGLIO, L.; KORONTZI, S. O.; WENS, J.; MORISETTE, J. T.; ROY, D.; DESCLOITRES, J.; ALLEAUME, S.; PETITCOLIN, F.; KAUFMAN, Y. 2002. The Modis fire products. **Remote Sensing of Environment**, n.83, p.244-262.
- JOHNSON, D. E. 1998. **Applied Multivariate Methods for Data Analysts**. Duxbury Press, 1998. 587p.
- JOHNSON, R. A.; WICHERN, D. W. 1988. **Applied Multivariate Statistical Analysis**. 2. ed. New Jersey: Prentice Hall International, 1988. 607p.
- KENNEDY, P.J.; BELWARD, A.S.; GREGOIRE, J.M. 1994. An improved approach to fire monitoring in West Africa using AVHRR data. **International Journal of Remote Sensing**, v.15, p.2235-2225.
- KISHI, R.T. 2001. Estudo das Relações entre nitrato nas águas superficiais e o uso do solo. **Série em Ciências Geodésicas**, v.1, p.243-257.
- KITE, G.; PIETRONIRO, A. 1996. Remote Sensing application in hydrological modeling. **Hydrological Sciences Journal**, v. 41, n.4.
- KOREN, V.; KOGAN, F. 1995. Parametrization of Hydrological Model using NOAA/AVHRR data. **IGARSS' 95**, IEEE.
- KOSTER, R. D.; HOUSER, P. R.; ENGMAN, E. T. 1999. Remote Sensing May Provide Unprecedented Hydrological data. Disponível em: <http://www.agu.org/eos_elec>
- LILLESAND, T. M.; KIEFER, R. W. 1994. **Remote Sensing and Image Interpretation**. 3. ed. New York: John Wiley & Sons, 1994. 750p.
- LU, Z.; MEYER, D. J. 2002. Study of high SAR backscattering caused by an increase of soil moisture over a sparsely vegetated area: implications for characteristics of backscattering. **Int. J. Remote. Sensing**, v.23, n.6, p.1063 – 1074.
- MAFFRA, C.Q.T.; CENTENO, J.A.S. 2002. The use of Remote Sensing for soil moisture detection: application in the study of mass movements. 29th ISRE Congress, Commission I, Buenos Aires, CD room.
- MARKHAM, B. L.; BARKER, J. L. 1986. Landsat MSS and TM post-calibration dynamic ranges, exoatmospheric reflectances and at-satellite temperatures. EOSAT Landsat Technical notes, v.1, p. 3-8.
- McKEAN, J.; BUECHEL, S.; GAYDOS, L. 1991. Remote Sensing and Landslide Hazard Assessment. In: **Photogrammetric Engineering and Remote Sensing**, v. 57, n.9, p.1185-1193.
- MORAN, M. S.; HMER, D. C.; JIAGUO, Q.; KERR, Y. 2002. Comparison of ERS-2 SAR and Landsat TM imagery for monitoring agricultural crop and soil conditions. **Remote Sensing of Environment**, v.79, p.243 - 252.

- MORENO, J. F.; GONZALES, M.C.; ALONSO, L.; LE HÉGARAT-MASCLE S.; ELEM, F.; NORMAND, M. 1999. Survey of remote sensing data analysis methods. **European Research Project "AIMWATER"**.
- MULLER E.; DECAMPS H. 2000. Modeling soil moisture-reflectance. **Remote Sensing of Environment**, v.76, p.173 - 180.
- MUSICK, G.; PELLETIER, R. 1986. Response of some Thematic Mapper ratios to variation in soil water contents. **Photogrammetric Engineering and Remote Sensing**, v.52, n.10, p. 1661- 1668.
- NEUSCH, T.1999. **Multi-Frequency and Multi-Polarization Synthetic Aperture Radar for Modelling Hydrological Parameters**. Karlsruhe, 1999. 128f. (PhD – Thesis) University of Karlsruhe.
- PARLOW, E. 1996. Correction of terrain controlled illumination effects in satellite data. In: **Progress in Environmental Remote Sensing Research and application**. 1996. Rotterdam p.139 – 145.
- PRATA, A. J.; CASELLES, V.; COLL, C., SOBRINO, J.A.; OTTLÉ, C. 1995. Thermal remote sensing of land surface temperature from satellites: current status and future prospects. **Remote Sensing Review**, v.12, p. 175-224
- RIBEIRO, S.R.A. 2003. **Integração de imagens Landsat TM e dados auxiliares para a delimitação automática de unidades fisionômicas usando redes neurais artificiais**. Curitiba, 2003, 160f. Tese de Doutorado – Departamento de Geomática, Universidade Federal do Paraná.
- ROMBACH, M.; MAUSER, W. 1997. Multi-Annual analysis of ERS surface soil moisture measurements of different land uses. 3rd ERS Symposium, Florence, 1997. **Abstracts**.
- ROY, D.P.; LEWIS, P.E.; JUSTICE, C.O. 2002. Burned area mapping using multi-temporal moderate spatial resolution data - a bi-directional reflectance model-based expectation approach. **Remote Sensing of Environment**, v.83, p.263 – 286.
- SANDMEIER, S. R. 1995. A Physically-Based Radiometric Correction Model – Correction of Atmospheric and Illumination Effects in Optical Satellite Data of Rugged Terrain. **Remote Sensing Series**, v.26. University of Zurich, Dep. Geography, 144p.
- SANDHOLT, I.; RASMUSSEN, K.; ANDERSEN, J. 2002. A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. **Remote Sensing of Environment**, v.79, p.213-224.
- STORL, J. 1994. Deriving a High Resolution Soil Moisture Index from LANDSAT – TM data. **ISPRS**, v. 30, Manaus, Brazil.
- THOME, K. 1999. **Algorithm Theoretical basis Document for ASTER level 2B1 – Surface Radiance and ASTER level 2b5**. University of Arizona. 45p.

- VERMOTE, E. F.; VERMEULEN, A. 1999. **Atmospheric Correction Algorithm: Spectral Reflectances (MOD09)**. University of Maryland. 107p.
- WAGNER, W. 1988. **Soil moisture retrieval from ERS Scatterometer data**. Wien, 1988. (PhD thesis). University of Wien.
- WALSH, S. J.; BUTLER, D. R. 1997. Morphometric and multispectral image analysis of debris flows for natural hazard assessment. **Geocarto International**, v.12, n.1, p.59-70.
- WANG, Z.; LI, Z. L. 1997. A physics-based algorithm for retrieving land-surface emissivity and temperature from EOS/MODIS data. **IEEE Trans. Geosci. Remote Sens.**, v.35, n.4, p.980-996.
- WANG, Z. 1999. MODIS Land Surface Temperature Algorithm Theoretical Basis Document. University of California. 77p.
- WEIDONG, L.; BARET, F.; XINGFA, G.; QINGXI, T.; LANFEN, Z.; BING, Z. 2002. Relating soil surface moisture to reflectance. **Remote Sensing of Environment**, v.81, p.238-246.

ANEXO I - DADOS DE ACÚMULO DE CHUVA

O acúmulo de chuva foi calculado utilizando-se os índices de 2,4, 6 e 8 dias. Calcula-se os dois dias anteriores a aquisição da imagem + $\frac{1}{2}$ do dia de aquisição da imagem. Por exemplo, para o dia 22 de novembro de 2002 o acumulado de 2 dias corresponde a pluviosidade do dia 20, 21 e $\frac{1}{2}$ da pluviosidade do dia 22 de novembro.

TABELA A1 – ACUMULADOS DE CHUVA

Landsat_22/NOV/02				
Estação	Ac.2dias	Ac.4dias	Ac.6dias	Ac.8dias
Acerra	8,6	8,6	16,4	
Giugliano	6,6	7,0	11,4	
Giugliano L.	7,0	7,0	12,8	
Striano	9,5	9,5	15,1	
Terzigno	15,1	15,1	24,9	
Villaricca	10,6	11,0	15,6	
Agropoli	3,2	3,2	15,9	
Altavilla	2,2	2,2	20,6	
Baronissi	7,5	7,5	18,9	
Battipaglia	2,5	2,5	15,6	
Buccino	0,0	0,0	12,8	
Buonabitacolo	1,4	1,4	17,9	
Casalvelino	12,6	12,6	20,9	
Castel S_L	2,3	n.p	n.p	
Gromola	6,2	6,2	19,4	
Policastro B.	3,5	3,5	8,0	
S. Marzano	12,8	12,8	18,5	
Ariano	1,4	1,6	6,0	
Mirabella	0,0	0	4,8	
Montella	n.p	n.p	n.p	

ASTER_25/JUN/01				
Estação	Ac.2dias	Ac.4dias	Ac.6dias	Ac.8dias
Acerra	0	0	0	3
Baronissi	0	0	2	16,7
Battipaglia	0	0	1,2	22,5
Mirabella	0	0	12,8	17,0
Montella	0	0	4	16,8
S. Marzano	0	0	0	25,1
Striano	0	0	0	20,2

ASTER_28/JAN/02				
Estação	Ac.2dias	Ac.4dias	Ac.6dias	Ac.8dias
Altavilla	0,4	10,8	11,0	11,2
Baronissi	4,2	31,0	31,0	31,0
Battipaglia	0,0	7,2	7,4	7,4
Castel S.L	0	25,6	25,6	25,8
Gromola	0,5	11,1	11,3	11,3
S. Marzano	0,0	19,0	19,0	23,7
Terzigno	0,3	34,3	34,5	34,9

ASTER_26/SET/00

Estação	Ac.2dias	Ac.4dias	Ac.6dias	Ac.8dias
Acerra	0	0	0	0,2
Giugliano L	0	0	0	0,2
S. Marzano	0	0	0	0
Striano	0	0	0	0,2
Terzigno	0	0	0	0,2
Villaricca	0	0	0	0,4

ASTER_20/MAIO/02

Estação	Ac.2dias	Ac.4dias	Ac.6dias	Ac.8dias
Agropoli	0,5	0,5	0,5	13,9
Baronissi	0,3	0,7	1,1	1,8
Castel S_L	4,6	4,6	4,6	24,9
Gromola	5,3	5,5	5,7	13,1

ASTER_17/AGO/02

Estação	Ac.2dias	Ac.4dias	Ac.6dias	Ac.8dias
Altavilla	0,4	2,0	32,6	35,8
Buccino	4,3	4,3	46,6	n.p
Castel S_L	0	0,7	n.p	n.p

ASTER_20/JUL/01

Estação	Ac.2dias	Ac.4dias	Ac.6dias	Ac.8dias
Buccino	0	1,2	1,2	2,2
Buonabitacolo	0	0,2	2,4	2,4
Casalvelino	np	np	np	np

MODIS_06/ABRIL/02

Estação	Ac.2dias	Ac.4dias	Ac.6dias	Ac.8dias
Acerra	55,6	57,8	57,8	57,8
Agropoli	42,1	61,6	61,6	61,6
Altavilla	46,2	67,6	67,8	67,8
Baronissi	48,3	52,3	52,3	52,3
Battipaglia	45,8	53,4	53,4	53,4
Castel S_L	34,8	61,9	61,9	61,9
Giugliano	41,7	45,3	45,3	45,3
Giugliano L	38,2	41,6	53,6	55,2
Gromola	64	84,6	84,6	84,6
Montella	35,8	41,4	41,4	41,4
S. Marzano	37	39,2	39,2	39,2
Striano	47	50,4	50,4	50,4
Terzigno	47,4	51	51	51
Villaricca	46,8	51,4	51,4	51,4

MODIS_23/ABRIL/02

Estação	Ac.2dias	Ac.4dias	Ac.6dias	Ac.8dias
Acerra	8,1	9,5	21,5	21,5
Agropoli	2,4	5,7	11,2	11,2
Altavilla	6,6	6,8	10,8	11
Baronissi	4,4	5,4	11,6	11,6
Battipaglia	13,2	13,2	25,6	25,6
Castel S_L	9,9	9,9	13,6	13,6
Giugliano	20,2	20,2	21,4	21,4
Giugliano L.	18,3	18,5	25,9	26,1
Gromola	5	5,8	10,8	11

Montella	-	-	-	-
S. Marzano	11,3	11,3	16,1	16,1
Striano	22,3	22,5	26,5	26,5
Terzigno	20,1	24,7	31,1	31,3
Villaricca	13	13,4	15,2	15,4

TABELA A2 - LOCALIZAÇÃO DAS ESTAÇÕES

Estações	Latitude Roma 1940	Longitude Roma 1940	UTM Europeu 1950	UTM Europeu 1950
Acerra	N_40°58'31"	E_14°26'50"	4536238 N	453490 E
Giugliano	N_40°56'55"	E_14°04'12"	4533547 N	421720 E
Giugliano (L.Patria)	N_40°55'20"	E_14°12'00"	4530509 N	432636 E
Striano	N_40°49'30"	E_14°34'35"	4519495 N	464277 E
Terzigno	N_40°48'25"	E_14°28'38"	4517536 N	455903 E
Villaricca	N_40°54'37"	E_14°06'54"	4529432 N	425531 E
Agropoli	N_40°22'51"	E_15°02'06"	4470284 N	503036 E
Altavilla	N_40°30'30"	E_15°04'51"	4484439 N	506914 E
Baronissi	N_40°44'31"	E_14°46'44"	4510392 N	481396 E
Battipaglia	N_40°35'01"	E_14°58'58"	4492792 N	498608 E
Buccino	N_40°35'15"	E_15°23'25"	4493297 N	533093 E
Buonabitacolo	N_40°17'30"	E_15°38'04"	4460579 N	553993 E
Casalvelino	N_40°11'36"	E_15°07'58"	4449479 N	511368 E
Castel S. Lor	N_40°26'20"	E_15°02'34"	4476728 N	503693 E
Gromola	N_40°28'23"	E_14°59'27"	4480520 N	499288 E
Policastro B.	N_40°04'35"	E_15°31'57"	4436626 N	545471 E
S. Marzano	N_40°46'26"	E_14°35'21"	4513996 N	465394 E
Ariano	N_41°08'00"	E_15°12'00"	4553836 N	516852 E
Mirabella	N_41°04'48"	E_14°56'35"	4547898 N	495282 E
Montella	N_40°50'51"	E_15°02'03"	4522086 N	502945 E